



Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Nataša Tošanović

**UNAPREĐENJE PROIZVODNIH
PROCESA PRIMJENOM PRINCIPA
POVLAČENJA**

DOKTORSKI RAD

Zagreb, 2018.



Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Nataša Tošanović

**UNAPREĐENJE PROIZVODNIH
PROCESA PRIMJENOM PRINCIPA
POVLAČENJA**

DOKTORSKI RAD

Mentor: Prof. dr. sc. Nedeljko Štefanić

Zagreb, 2018.



University of Zagreb

FACULTY OF MECHANICAL ENGINEERING AND NAVAL
ARCHITECTURE

Nataša Tošanović

**IMPROVEMENT OF PRODUCTION
PROCESSES BY APPLYING PULL
PRINCIPLES**

DOCTORAL DISSERTATION

Supervisor: Prof. Nedeljko Štefanić, PhD

Zagreb, 2018.

PODACI ZA BIBLIOGRAFSKU KARTICU

UDK:	662.2.03
Ključne riječi:	Vitka proizvodnja, povlačenje materijala mehanizmi povlačenja materijala, proizvodni proces
Znanstveno područje:	Tehničke znanosti
Znanstveno polje:	Strojarstvo
Institucija u kojoj je rad izrađen:	Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje
Mentor rada:	Prof. dr. sc. Nedeljko Štefanić
Broj stranica:	128
Broj tablica:	29
Broj slika:	68
Broj korištenih bibliografskih jedinica:	42
Datum obrane:	8. 11. 2018.
Povjerenstvo:	Dr. sc. Nedeljko Štefanić, redoviti profesor Dr. sc. Goran Đukić, redoviti profesor Dr. sc. Ivica Veža, redoviti profesor
Institucija u kojoj je rad pohranjen:	Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje

Karlu...

ZAHVALA

Prije svega, zahvaljujem se svom mentoru prof. dr. sc. Nedeljku Štefaniću na savjetima, uloženom trudu i neizmjernoj podršci tijekom izrade doktorskog rada.

Zahvaljujem se docentu Hrvoju Cajneru na pomoći i savjetima kod statističke obrade podataka. Hvala i članovima Povjerenstva za ocjenu i obranu doktorskog rada prof. dr. sc. Ivici Veži i prof. dr. sc. Goranu Đukiću na strpljenju pri čitanju i recenziji rada te sugestijama.

Zahvaljujem se kolegama dr. sc. Miri Hegediću i Mihaelu Gudlinu koji su nesebično preuzeli dio obveza na Katedri za upravljanje proizvodnjom što mi je omogućilo da vrijeme maksimalno posvetim doktorskom radu.

Neizmjerно hvala i kolegici docentici Morani Mihaljević na moralnoj podršci u trenucima kada su se okolnosti za izradu doktorskog rada činile teškim.

Hvala i dragoj kolegici Ani Kelemen Herceg na podršci i razgovorima koji su mi puno značili.

Hvala svim kolegama na Zavodu za industrijsko inženjerstvo na podršci.

Hvala mojim dragim roditeljima, bratu i njegovoj obitelji što su uz mene u svakom trenutku.

Hvala mom suprugu Nenadu koji je čvrsti oslonac i podražka i koji je preuzeo većinu brige za našeg sina Karla kada sam završavala doktorski rad.

I na kraju, najviše hvala mom sinu Karlu, mom pokretaču i inspiraciji, koji me iz dana u dan uči kako je život lijep i da ga lijepim čine male stvari.

SADRŽAJ

POPIS SLIKA	
POPIS TABLICA	
POPIS KRATICA	
POPIS OZNAKA	
SAŽETAK / SUMMARY	
1. UVOD	1
1.1 Trenutno stanje razvoja predmetnog područja	2
1.2 Cilj i hipoteza istraživanja.....	7
1.3 Metodologija i plan istraživanja	7
1.4 Očekivani znanstveni doprinos	8
2. VITKA PROIZVODNJA	9
2.1 Povijest Vitke proizvodnje.....	9
2.2 Principi Vitke proizvodnje	11
3. PRINCIP POVLAČENJA MATERIJALA	14
3.1 Mehanizmi upravljanja proizvodnjom	16
3.1.1 Kanban	18
3.1.2 Conwip.....	19
3.1.3 Hibrid Kanban/Conwip	21
3.1.4 DBR – Drum-buffer-rope	22
4. USPOREDBA MEHANIZAMA UPRAVLJANJA PROIZVODNJOM	
 PRIMJENOM SIMULACIJE	25

4.1	Opis simulacijskog modela	25
4.2	Validacija simulacijskog modela.....	27
4.2.1	Validacija Kanban modela	29
4.2.2	Validacija Conwip modela.....	29
4.2.3	Validacija Hibrid modela.....	30
4.2.4	Validacija DBR modela	31
4.3	Definiranje utjecajnih parametara i mjera performansi proizvodnog procesa	33
4.4	Eksperimentalni rad	35
4.4.1	Analiza procesa – Kanban	37
4.4.2	Analiza procesa – CONWIP	55
4.4.3	Analiza procesa – Hibrid Kanban/CONWIP	69
4.4.4	Analiza procesa DBR.....	84
5.	ANALIZA REZULTATA ISTRAŽIVANJA.....	99
6.	PRIMJENA REZULTATA ISTRAŽIVANJA	108
6.1	Testiranje na odabranom modelu.....	108
7.	ZAKLJUČAK.....	115
8.	LITERATURA	117
9.	PRILOG	121
	ŽIVOTOPIS	
	BIOGRAPHY	

POPIS SLIKA

SLIKA 1. PET PRINCIPA VITKE PROIZVODNJE	11
SLIKA 2. AKTIVNOSTI U PROIZVODNOM PROCESU	12
SLIKA 3. <i>PUSH</i> SUSTAV	14
SLIKA 4: <i>PULL</i> SUSTAV	15
SLIKA 6. KANBAN MEHANIZAM UPRAVLJANJA PROIZVODNJOM [26]	19
SLIKA 7. CONWIP MEHANIZAM UPRAVLJANJA [26]	20
SLIKA 9. DBR - DRUM- BUFFER- ROPE	23
SLIKA 10: PROIZVODNI PROCES	25
SLIKA 11: NORMALIZIRANI PAPIR OSTATAKA ZA MATEMATIČKI MODEL ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM KANBAN MEHANIZMOM UPRAVLJANJA	41
SLIKA 12: SLUČAJNO RASIPANJE OSTATAKA U ODNOSU NA REDOSLIJED IZVOĐENJA PLANA ZA MATEMATIČKI MODEL ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM KANBAN MEHANIZMOM UPRAVLJANJA	42
SLIKA 13. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI OVISNO O RAZINI KOEFIKIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU POSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 5 KANBAN KARTICA PO RADNOM MJESTU	42
SLIKA 14. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI OVISNO O RAZINI KOEFIKIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU POSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 5 KANBAN KARTICA PO RADNOM MJESTU	43
SLIKA 15: 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI OVISNO O RAZINI KOEFIKIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU NEPOSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 5 KANBAN KARTICA PO RADNOM MJESTU	44
SLIKA 16. NORMALIZIRANI PAPIR OSTATAKA ZA MATEMATIČKI MODEL ZA IZRAČUN VODEĆEG VREMENA KOD UPRAVLJANJA PROCESOM KANBAN MEHANIZMOM UPRAVLJANJA	49
SLIKA 17. SLUČAJNO RASIPANJE OSTATAKA U ODNOSU NA REDOSLIJED IZVOĐENJA PLANA ZA MATEMATIČKI MODEL ZA IZRAČUN VODEĆEG VREMENA KOD UPRAVLJANJA PROCESOM KANBAN MEHANIZMOM UPRAVLJANJA	50
SLIKA 18. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFIKIJENTA VARIJACIJE I VREMENA TRAJANJA OPERACIJE ZA SLUČAJ NEPOSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 2 KANBAN KARTICE PO RADNOM MJESTU	51
SLIKA 19. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFIKIJENTA VARIJACIJE I VREMENA TRAJANJA OPERACIJE ZA SLUČAJ NEPOSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 5 KANBAN KARTICA PO RADNOM MJESTU	51

SLIKA 20. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OPERACIJE ZA SLUČAJ POSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 2 KANBAN KARTICE PO RADNOM MJESTU	52
SLIKA 21. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OPERACIJE ZA SLUČAJ POSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 5 KANBAN KARTICA PO RADNOM MJESTU	53
SLIKA 22. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OPERACIJE ZA SLUČAJ POSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 2 KANBAN KARTICE PO RADNOM MJESTU	53
SLIKA 23. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OPERACIJE ZA SLUČAJ POSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 5 KANBAN KARTICA PO RADNOM MJESTU	54
SLIKA 24. NORMALIZIRANI PAPIR OSTATAKA ZA MATEMATIČKI MODEL ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM CONWIP MEHANIZMOM UPRAVLJANJA	58
SLIKA 25. SLUČAJNO RASIPANJE OSTATAKA U ODNOSU NA REDOSLIJED IZVOĐENJA PLANA ZA MATEMATIČKI MODEL ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM CONWIP MEHANIZMOM UPRAVLJANJA	59
SLIKA 26. 3D MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU POSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 2 CONWIP KARTICE PO RADNOM MJESTU (10 CONWIP UKUPNO)	59
SLIKA 27. 3D MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU NEPOSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 2 CONWIP KARTICE PO RADNOM MJESTU (10 CONWIP U	60
SLIKA 28. NORMALIZIRANI PAPIR OSTATAKA ZA MATEMATIČKI MODEL ZA IZRAČUN VODEĆEG VREMENA KOD UPRAVLJANJA PROCESOM CONWIP MEHANIZMOM UPRAVLJANJA	65
SLIKA 29. SLUČAJNO RASIPANJE OSTATAKA U ODNOSU NA REDOSLIJED IZVOĐENJA PLANA ZA MATEMATIČKI MODEL ZA IZRAČUN VODEĆEG VREMENA KOD UPRAVLJANJA PROCESOM CONWIP MEHANIZMOM UPRAVLJANJA	65
SLIKA 30. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU SLUČAJU POSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 3 KARTICE PO RADNOM MJESTU (15 CONWIP KARTICA ZA CIJELI PROCES)	66
SLIKA 31. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU SLUČAJU NEPOSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 2 CONWIP KARTICE PO RADNOM MJESTU (10 CONWIP UKUPNO)	67
SLIKA 32. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU POSTOJANJA USKOG GRILA U PROCESU I ZA SLUČAJ 3 CONWIP KARTICE PO RADNOM MJESTU (15 CONWIP KARTICA UKUPNO)	67

SLIKA 33. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU POSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 2 CONWIP KARTICE PO RADNOM MJESTU (10 CONWIP KARTICA ZA CIJELI PROCES)	68
SLIKA 34. NORMALIZIRANI PAPIR OSTATAKA ZA MATEMATIČKI MODEL ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM HIBRIDNIM MEHANIZMOM UPRAVLJANJA	73
SLIKA 35. SLUČAJNO RASIPANJE OSTATAKA U ODNOSU NA REDOSLIJED IZVOĐENJA PLANA ZA MATEMATIČKI MODEL ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM HIBRIDNIM MEHANIZMOM UPRAVLJANJA	73
SLIKA 36. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU SLUČAJU POSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 3 CONWIP KARTICE PO RADNOM MJESTU (15 KARTICA ZA CIJELI PROCES)	74
SLIKA 37. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU SLUČAJU POSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 3 CONWIP KARTICE PO RADNOM MJESTU (15 KARTICA ZA CIJELI PROCES)	75
SLIKA 38. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU SLUČAJU NEPOSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 3 CONWIP KARTICE PO RADNOM MJESTU (15 KARTICA ZA CIJELI PROCES)	75
SLIKA 39. NORMALIZIRANI PAPIR OSTATAKA ZA MATEMATIČKI MODEL ZA IZRAČUN VODEĆEG VREMENA KOD UPRAVLJANJA PROCESOM HIBRIDNIM MEHANIZMOM UPRAVLJANJA	79
SLIKA 40. SLUČAJNO RASIPANJE OSTATAKA U ODNOSU NA REDOSLIJED IZVOĐENJA PLANA ZA MATEMATIČKI MODEL ZA IZRAČUN VODEĆEG VREMENA KOD UPRAVLJANJA PROCESOM HIBRIDNIM MEHANIZMOM UPRAVLJANJA	80
SLIKA 41. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU SLUČAJU NEPOSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 2 CONWIP KARTICE PO RADNOM MJESTU	80
SLIKA 42. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU NEPOSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 2 CONWIP KARTICE PO RADNOM MJESTU	81
SLIKA 43. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU SLUČAJU POSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 2 CONWIP KARTICE PO RADNOM MJESTU	82
SLIKA 44. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU POSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 3 CONWIP KARTICE PO RADNOM MJESTU	83
SLIKA 45. NORMALIZIRANI PAPIR OSTATAKA ZA MATEMATIČKI MODEL ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM DBR MEHANIZMOM UPRAVLJANJA	87

SLIKA 46. SLUČAJNO RASIPANJE OSTATAKA U ODNOSU NA REDOSLIJED IZVOĐENJA PLANA ZA MATEMATIČKI MODEL ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM DBR MEHANIZMOM UPRAVLJANJA	88
SLIKA 47. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU NEPOSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 3,5 DBR KARTICE PO RADNOM MJESTU (14 DBR KARTICA ZA CIJELI PROCES)	88
SLIKA 48. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU NEPOSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 3,5 DBR KARTICE PO RADNOM MJESTU (14 DBR KARTICA ZA CIJELI PROCES)	89
SLIKA 49. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU POSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 3,5 DBR KARTICE PO RADNOM MJESTU (14 DBR KARTICA ZA CIJELI PROCES)	90
SLIKA 50. NORMALIZIRANI PAPIR OSTATAKA ZA MATEMATIČKI MODEL ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM DBR MEHANIZMOM UPRAVLJANJA	94
SLIKA 51. SLUČAJNO RASIPANJE OSTATAKA U ODNOSU NA REDOSLIJED IZVOĐENJA PLANA ZA MATEMATIČKI MODEL ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM DBR MEHANIZMOM UPRAVLJANJA	95
SLIKA 52. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU NEPOSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 2,5 DBR KARTICE PO RADNOM MJESTU (9 DBR KARTICA ZA CIJELI PROCES)	96
SLIKA 53. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU POSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 2,5 DBR KARTICE PO RADNOM MJESTU (9 DBR KARTICA ZA CIJELI PROCES)	96
SLIKA 54. KONTURNI PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU POSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 3,5 DBR KARTICE PO RADNOM MJESTU (14 DBR KARTICA ZA CIJELI PROCES)	97
SLIKA 55. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU POSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 2,25 DBR KARTICE PO RADNOM MJESTU (9 DBR KARTICA ZA CIJELI PROCES)	97
SLIKA 56. 3D PRIKAZ MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA OVISNO O RAZINI KOEFICIJENTA VARIJACIJE I VREMENA TRAJANJA OBRADU U SLUČAJU POSTOJANJA USKOG GRLO U PROCESU I ZA SLUČAJ 3,5 DBR KARTICE PO RADNOM MJESTU (14 DBR KARTICA ZA CIJELI PROCES)	98
SLIKA 57. USPOREDBA MJERNE PERFORMANSE PRODUKTIVNOST ZA $CV=0,86$, $T=5$ MIN ZA PROCES KOJI NEMA USKO GRLO, $WIP=15$	99
SLIKA 58. USPOREDBA MJERNE PERFORMANSE PRODUKTIVNOST ZA $CV=0,86$, $T=5$ MIN ZA PROCES KOJI IMA USKO GRLO, $WIP=15$	100

SLIKA 59. USPOREDBA MJERNE PERFORMANSE PRODUKTIVNOST ZA $CV=0,25$, $T=5$ MIN ZA PROCES KOJI NEMA USKO GRLO, $WIP=15$	101
SLIKA 60. USPOREDBA MJERNE PERFORMANSE PORODUKTIVNOST ZA $CV=0,25$, $T=5$ MIN ZA PROCES KOJI IMA USKO GRLO, $WIP=15$	102
SLIKA 61. USPOREDBA MJERNE PERFORMANSE PRODUKTIVNOST ZA $CV=0,25$, $T=60$ MIN ZA PROCES KOJI NEMA USKO GRLO	102
SLIKA 62. USPOREDBA MJERNE PERFORMANSE VODEĆE VRIJEME ZA $CV=0,25$, $T=40$ MIN ZA PROCES KOJI NEMA USKO GRLO, $WIP=15$	103
SLIKA 63. USPOREDBA MJERNE PERFORMANSE VODEĆE VRIJEME ZA $CV=0,25$, $T=40$ MIN ZA PROCES KOJI IMA USKO GRLO, $WIP=15$	103
SLIKA 64. USPOREDBA MJERNE PERFORMANSE VODEĆE VRIJEME ZA $CV=0,86$, $T=40$ MIN ZA PROCES KOJI NEMA USKO GRLO, $WIP=15$	104
SLIKA 65. USPOREDBA MJERNE PERFORMANSE VODEĆE VRIJEME ZA $CV=0,86$, $T=40$ MIN ZA PROCES KOJI IMA USKO GRLO, $WIP=15$	104
SLIKA 66. USPOREDBA MJERNE PERFORMANSE PRODUKTIVNOST U OVISNOSTI O BROJU UPRAVLJAČKIH KARTICA ZA $CV=0,25$, $T=60$ MIN ZA PROCES KOJI IMA USKO GRLO	105
SLIKA 67. USPOREDBA MJERNE PERFORMANSE PRODUKTIVNOST U OVISNOSTI O BROJU UPRAVLJAČKIH KARTICA ZA $CV=0,25$, $T=60$ MIN ZA PROCES KOJI NEMA USKO GRLO	106
SLIKA 68. VODEĆE VRIJEME $CV=1,5$, $T=4$ MIN, $BR=1$ KOM/RM	113

POPIS TABLICA

TABLICA 1. VALIDACIJA SIMULACIJSKOG MODELA – <i>PUSH</i>	28
TABLICA 2. VALIDACIJA SIMULACIJSKOG MODELA – <i>CONWIP</i>	28
TABLICA 3. VALIDACIJA KANBAN MODELA – PRVI GRANIČNI UVJET	29
TABLICA 4. VALIDACIJA KANBAN MODELA – DRUGI GRANIČNI UVJET	29
TABLICA 5. VALIDACIJA <i>CONWIP</i> MODELA – PRVI GRANIČNI UVJET	29
TABLICA 6. VALIDACIJA KANBAN MODELA – DRUGI GRANIČNI UVJET	30
TABLICA 7. VALIDACIJA HIBRIDNOG <i>CONWIP</i> /KANBAN MODELA – PRVI GRANIČNI UVJET	31
TABLICA 8. VALIDACIJA HIBRIDNOG <i>CONWIP</i> /KANBAN MODELA – DRUGI GRANIČNI UVJET	31
TABLICA 9. VALIDACIJA <i>DBR</i> MODELA – GRANIČNI UVJET	32
TABLICA 10.: RAZINE UTJECAJNIH PARAMETARA	35
TABLICA 11. ANALIZA VARIJANCE MATEMATIČKOG MODELA KOJI OPISUJE UTJECAJ VARIRANIH PARAMETARA NA PRODUKTIVNOST KADA SE PROCESOM UPRAVLJA KANBAN MEHANIZMOM UPRAVLJANJA	37
TABLICA 12. VELIČINE KOJE OPISUJU KVALITETU DOBIVENOG MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM KANBAN MEHANIZMOM UPRAVLJANJA	38
TABLICA 13. ANALIZA VARIJANCE MATEMATIČKOG MODELA KOJI OPISUJE UTJECAJ VARIRANIH PARAMETARA NA VODEĆE KADA SE PROCESOM UPRAVLJA KANBAN MEHANIZMOM UPRAVLJANJA	46
TABLICA 14. VELIČINE KOJE OPISUJU KVALITETU DOBIVENOG MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA KOD UPRAVLJANJA PROCESOM KANBAN MEHANIZMOM UPRAVLJANJA	47
TABLICA 15. ANALIZA VARIJANCE MATEMATIČKOG MODELA KOJI OPISUJE UTJECAJ VARIRANIH PARAMETARA NA PRODUKTIVNOST KADA SE PROCESOM UPRAVLJA <i>CONWIP</i> MEHANIZMOM UPRAVLJANJA	56
TABLICA 16. VELIČINE KOJE OPISUJU KVALITETU DOBIVENOG MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM <i>CONWIP</i> MEHANIZMOM UPRAVLJANJA	57
TABLICA 17. ANALIZA VARIJANCE MATEMATIČKOG MODELA KOJI OPISUJE UTJECAJ VARIRANIH PARAMETARA NA VODEĆE VRIJEME KADA SE PROCESOM UPRAVLJA <i>CONWIP</i> MEHANIZMOM UPRAVLJANJA	62
TABLICA 18. VELIČINE KOJE OPISUJU KVALITETU DOBIVENOG MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA KOD UPRAVLJANJA PROCESOM <i>CONWIP</i> MEHANIZMOM UPRAVLJANJA	63
TABLICA 19. ANALIZA VARIJANCE MATEMATIČKOG MODELA KOJI OPISUJE UTJECAJ VARIRANIH PARAMETARA NA PRODUKTIVNOST KADA SE PROCESOM UPRAVLJA HIBRIDNIM MEHANIZMOM UPRAVLJANJA	70
TABLICA 20. VELIČINE KOJE OPISUJU KVALITETU DOBIVENOG MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM HIBRIDNIM MEHANIZMOM UPRAVLJANJA	71
TABLICA 21. ANALIZA VARIJANCE MATEMATIČKOG MODELA KOJI OPISUJE UTJECAJ VARIRANIH PARAMETARA NA VODEĆE VRIJEME KADA SE PROCESOM UPRAVLJA HIBRIDNIM MEHANIZMOM UPRAVLJANJA	76
TABLICA 22. VELIČINE KOJE OPISUJU KVALITETU DOBIVENOG MATEMATIČKOG MODELA ZA IZRAČUN VODEĆEG VREMENA KOD UPRAVLJANJA PROCESOM HIBRIDNIM MEHANIZMOM UPRAVLJANJA	77

TABLICA 23. ANALIZA VARIJANCE MATEMATIČKOG MODELA KOJI OPISUJE UTJECAJ VARIRANIH PARAMETARA NA PRODUKTIVNOST KADA SE PROCESOM UPRAVLJA DBR MEHANIZMOM UPRAVLJANJA	84
TABLICA 24. VELIČINE KOJE OPISUJU KVALITETU DOBIVENOG MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM DBR MEHANIZMOM UPRAVLJANJA	85
TABLICA 25. ANALIZA VARIJANCE MATEMATIČKOG MODELA KOJI OPISUJE UTJECAJ VARIRANIH PARAMETARA NA PRODUKTIVNOST KADA SE PROCESOM UPRAVLJA DBR MEHANIZMOM UPRAVLJANJA	91
TABLICA 26. VELIČINE KOJE OPISUJU KVALITETU DOBIVENOG MATEMATIČKOG MODELA ZA IZRAČUN PRODUKTIVNOSTI KOD UPRAVLJANJA PROCESOM DBR MEHANIZMOM UPRAVLJANJA	93
TABLICA 27. USPOREDBA REZULTATA DOBIVENIH SIMULACIJOM SA REZULTATIMA DOBIVENIM MATEMATIČKIM IZRAČUNOM	110
TABLICA 28. REZULTATI DOBIVENI SIMULACIJOM ZA PROCES KOJI IMA USKO GRLO	110
TABLICA 29. USPOREDBA REZULTATA DOBIVENIH SIMULACIJOM SA REZULTATIMA IZ ČLANKA [11]	111

POPIS KRATICA

Kratika	Opis
ANOVA	<i>Analysis of variance</i> (Analiza varijance)
CONWIP	<i>Constant work in process</i> (Konstantan rad u procesu)
DBR	<i>Drum – buffer – rope</i> (Bubanj – međuspremnik – uže)
EPQ	Economic production quantity (Ekonomična serija proizvodnje)
FIFO	First in first out (Prvi ulazi prvi izlazi)
IMVP	<i>International motor vehicle program</i> (Međunarodni program o motornim vozilima)
JIT	<i>Just in time</i> (Upravo na vrijeme)
MRP	<i>Material Requirements Planning</i> (Planiranje potrebe za materijalom)
NUMMI	<i>New United Motor Manufacturing</i> (Zajednička zbornica motornih vozila General Motorsa i Toyote)
POLCA	<i>Paired-cell Overlapping Loops with Cards with Authorization</i> (Autorizacijske kartice za par radnih stanica)
RSM	<i>Response Surface Methodology</i> (Metoda odzivne površine)
TPS	<i>Toyota production system</i> (Toyotin proizvodni sustav)
WIP	<i>Work in process</i> (Rad u procesu)

POPIS OZNAKA

Oznaka	Jedinica	Značenje oznake
C	kom	Broj Conwip kartica u sustavu
C		Spremnik Conwip kartica
c		Conwip kartice
C_v		Koeficijent varijacije
D		Spremnik DBR kartica
d		DBR kartice
D	kom	Broj DBR kartica u sustavu
i		Oznaka broja proizvodne etape
inf		Informacija
K_i		Spremnik Kanban kartica u proizvodnoj etapi i
k		Kanban kartica
k_i	kom	Broj Kanban kartica u etapi i
LT	min	Vodeće vrijeme
MS_i		Međuspremnik u proizvodnoj etapi i
m		Materijal
N	kom	Broj komada gotovih proizvoda
P	kom/h	Produktivnost
p		Potražnja
P_o		Spremnik kartica o potražnji
RM_i		Radno mjesto u proizvodnoj etapi i

SAŽETAK

Kontinuirano unapređenje proizvodnje uvjet je svakom proizvođaču za opstanak na tržištu. Istraživanja pokazuju da veliki broj vodećih svjetskih proizvodnih poduzeća koristi principe Vitke proizvodnje za unapređenje svojih procesa. Osnovni princip Vitke proizvodnje je povlačenje materijala kroz proizvodni proces. Sinonim za povlačenje jest Kanban jer je to bio prvi razvijeni mehanizam upravljanja proizvodnjom kojim se realizira povlačenje materijala kroz proces a koji je razvijen u Toyoti, gdje su principi vitke proizvodnje i nastali. S godinama primjene ovog principa razvijaju se i drugi mehanizmi upravljanja obzirom na specifičnosti pojedinih proizvodnih procesa.

Cilj ovog istraživanja bio je analizirati kako parametri proizvodnog procesa, redom: koeficijent varijacije vremena obrade, vrijeme trajanja obrade, usko grlo, te broj upravljačkih kartica utječu na performanse proizvodnog procesa ovisno koji se mehanizam upravljanja koristi u procesu. Hipoteza rada je bila da je izborom odgovarajućeg mehanizma upravljanja proizvodnjom kojim se postiže povlačenje materijala kroz proces moguće optimalno unaprijediti performanse proizvodnog procesa. U tu svrhu provedeno je simulacijsko eksperimentiranje. Simulirana su četiri zasebna scenarija. U prvom scenariju proizvodni proces je upravljan Kanban mehanizmom upravljanja. U drugom, proizvodni proces je upravljan Conwip mehanizmom upravljanja, te i trećem i četvrtom scenariju proizvodni proces je upravljan redom Hibrid Kanban/Conwip te DBR mehanizmom upravljanja. Za sva četiri mehanizma upravljanja varirani su isti utjecajni parametri. Promatrane su mjerne performanse produktivnost i vodeće vrijeme te su navedene mjerne performanse uspoređene za svaki od mehanizama upravljanja. Rezultati su pokazali da za svaku kombinaciju vrijednosti ulaznih parametara mjerne performanse su različite ovisno o tome kojim mehanizmom upravljanja se upravlja proizvodnim procesom. Sukladno dobivenom zaključuje se da nije uvijek isti mehanizam upravljanja najbolji odabir za određeni proizvodni proces. Koji je mehanizam upravljanja najbolji odabir za određeni proces ovisi o razinama utjecajnih parametara proizvodnog procesa.

Ključne riječi: Vitka proizvodnja, princip povlačenje materijala mehanizmi upravljanja proizvodnjom, proizvodni proces

SUMMARY

In order to stay successful in business every production company needs to continuously improve its processes. Research has shown that a large number of leading world manufacturing companies use the principles of Lean production to improve their processes. The basic principle of Lean production is to pull of material through the production process. The synonym for the pull is Kanban because it was the first developed production control mechanism to achieve through a process developed in Toyota, where the principles of Lean production were created. With the years of application of this principle, other production control mechanisms are developed with regard to the specificity of individual production processes.

The aim of this research was to analyze how the production process parameters: coefficient of variation of processing time, processing time, bottleneck, and number of production control cards affect the performance of the production process depending on production control mechanism. The hypothesis of the research was that by selecting an appropriate pull it is possible to optimally improve the performance of the production process. Simulation experimentation was performed for this purpose. Four case scenarios were simulated. In the first case scenario the production process was controlled by Kanban. In the second one, production process was controlled by Conwip. In the third and the forth case scenarios the production process was controlled by Hybrid Kanban / Conwip and DBR. All four scenarios were simulated in such a way that the same production parameters have been varied. Productivity and lead time were observed, and then were compared for each of the control mechanisms. The results have shown that for each combination of input parameters, the performance measure varies depending on which control mechanism is applied in the production process. Based on these findings, it is concluded that not always the same control mechanism is the best choice for a particular process. Which is the best control mechanism for the particular process depends on the levels of influential parameters of the production process.

Key words: Lean production, pull principle, production control mechanisms, production process.

1. UVOD

Tijekom posljednjeg desetljeća stanje u globalnoj svjetskoj proizvodnji i tržištu postalo je prilično turbulentno i promjenjivo. Kako bi uspjeli odgovoriti na promjene u zahtjevima tržišta poduzeća se moraju konstantno prilagođavati. Sasvim je sigurno da proizvodna poduzeća koja žele opstati na tržištu moraju kontinuirano raditi na unapređenju proizvodnih procesa.

Istraživanje koje je proveo *Industry Week* i *Manufacturing Performance Institute* je pokazalo da 95% sjevernoameričkih poduzeća koja spadaju u klasu vodećih svjetskih poduzeća (eng. *world class manufacturnig*) koriste neku od metoda za unapređenje proizvodnje. Iz kategorije „*world class manufacturnig*“ najveći broj i to 39% koristi metodologiju vitke proizvodnje. Istraživanje je obuhvatilo 931 poduzeće iz SAD-a i Kanade [1]. Može se zaključiti da veliki dio vodećih svjetskih poduzeća koriste vitku proizvodnju kao metodologiju za kontinuirano unapređenje proizvodnje.

Koncept vitke proizvodnje potekao je iz Toyotinih proizvodnih pogona, zapravo iz Toyotinog proizvodnog sustava. Osnovni cilj je postići proizvodne procese koji brzo reagiraju na promjene u zahtjevima kupaca a to je moguće ukoliko se iz proizvodnih procesa eliminira sve nepotrebno i skрати ciklus proizvodnje [2], [3]. Jedan od temelja TPS-a je proizvodnja upravo na vrijeme (eng. *Just in time*, JIT). Kako bi postigla JIT Toyota je razvila Kanban sustav signalnih kartica pomoću kojih se povlači materijal kroz proizvodni proces, za razliku od masovne, serijske proizvodnje, gdje se materijal gura kroz proizvodni proces. Osnovna razlika između vitke i masovne proizvodnje, je u principu povlačenja materijala. U vitkoj proizvodnji kupac povlači proizvod na tržište, dok u masovnoj proizvodnji proizvod se gura prema kupcu. Upravo sustavom Kanban kartica Toyota je uspjela postići povlačenje materijala kroz proizvodnju što je doprinijelo fleksibilnosti proizvodnog sustava i bržem reagiranju na zahtjeve kupaca.

Kanban sustav Toyota je razvijala preko 10 godina, odnosno preko 10 godina je bilo potrebno Toyoti 1950-tih godina kako bi implementirala ideje povlačenja materijala pomoću signalnih kartica. Razlog tomu je što postoji niz preduvjeta za uspješnu primjenu ovakvog sustava, a to su prije svega male serije, kratka vremena namještanja strojeva i alata, stabilan proizvodni proces, dakle proizvodni proces sa malo varijacija, malo grešaka i dorade, te bez zastoja uzrokovanih bilo zastojem opreme, bilo nekim drugim poremećajima [4], [5].

Nakon što se uvidjelo da je povlačenje materijala vrlo dobar način da se odgovori sve većim zahtjevima na proizvodnju u smislu povećanja efikasnosti i fleksibilnosti, znanstvenici i inženjeri u praksi su počeli razvijati i druge sustave slične Kanban signalnom sustavu pomoću kojeg se upravlja tijekom materijala kroz proizvodni proces u cilju postizanja fleksibilnog proizvodnog sustava koji može brzo reagirati na zahtjeve kupaca.

Mnoga su istraživanja provedena s ciljem da se definiraju optimalni parametri pojedinih sustava [6], [7], [8], [9], [10], dok posljednjih 10-tak godina sve veći broj istraživanja nastoji utvrditi koji od mehanizama više odgovara s obzirom na zadane uvjete koji utječu na proizvodni proces [11], [12], [13], [14], [15], [16], [17], [18], [19], [20], [21]. Pregledom literature utvrđeno je kako određena istraživanja opovrgavaju druga [12], [19], te također unatoč velikom broju usporedbi pojedinih mehanizama nije napravljeno istraživanje koje bi obuhvatilo veći broj mehanizama i uzelo u obzir veći broj parametara koji značajno utječu na definirane preduvjete za povlačenje materijala u procesu. Tako na primjer samo mali broj istraživanja je kao bitan parametar uzeo u obzir utjecaj vremena namještanja stroja, a što je vrlo značajan parametar pri odabiru mehanizma upravljanja proizvodnjom. Stoga je potrebno provesti istraživanje koje bi uzelo u obzir parametre koji značajno utječu na preduvjete za uspješnu primjenu mehanizama upravljanja proizvodnjom, te utvrditi koji mehanizmi su bolji izbor za različite vrijednosti tih parametara. Temeljem rezultata takvog istraživanja potrebno je osmisliti metodu za donošenje odluke o izboru mehanizma upravljanja proizvodnjom obzirom na zadane uvjete, s ciljem postizanja fleksibilnog i efikasnog proizvodnog procesa, sa što kraćim ciklusom proizvodnje i što manje zaliha u procesu.

1.1 Trenutno stanje razvoja predmetnog područja

Od kako je razvijen Kanban signalni sustav u Toyotinom proizvodnom pogonima, primjena ovakvog sustava, kojemu je svrha postizanja povlačenja materijala kroz proces postaje sve raširenija a karakteristike samog mehanizma povlačenja prilagođavaju se specifičnostima pojedinih proizvodnih procesa. Naime još je Monden zaključio da tradicionalni Kanban sustav ima određene nedostatke, a to je da zahtjeva određene preduvjete da bi bio uspješno primijenjen a koje ponekad nije tako lako ostvariti [4]. Neki od tih preduvjeta su: varijabilnost u potražnji mora biti niska (potražnja treba biti skoro konstantna), raznolikost proizvoda (proizvodni program) mora biti niska, proces mora biti stabilan (bez

puno grešaka i vraćanja materijala u procesu, bez varijabilnosti u vremenima obrade, bez zastoja i čekanja), te vremena namještanja stroja trebaju biti svedena na minimum.

Kako bi bilo moguće ostvariti povlačenje materijala u proizvodnim pogonima sa velikim brojem različitih proizvoda 1990 godine Spearman, Woodruff i Hopp predlažu drugi sustav povlačenja materijala kojeg nazivaju „konstantna količina zaliha u procesu“ (eng. *Constant work in process - CONWIP*), a koji za razliku od klasičnog Kanban sustava ograničava ukupnu količinu zaliha u procesu, a signalne kartice postoje samo između skladišta (gdje prvotno stižu narudžbe) i prve operacije, a daljnji tijek materijala se odvija prema FIFO (eng. *First in – First out*) pravilu [22].

Kasnije, 1998. godine, Suri [23] predlaže POLCA sustav (eng. *Paired-cell Overlapping Loops with Cards with Authorization*), također za uvjete velike raznolikosti, koji koristi sustav odobravanja pokretanja proizvodnje na pojedinom stroju, odnosno radnoj stanici, na način da stroj/radna stanica ne može početi obradu sve dok na tom mjestu nije kartica sa prethodne i iduće operacije. Od tada POLCA se počinje uspješno primjenjivati u različitim proizvodnim sustavima [24], [25].

Boonlertvanich uvodi još jednu varijantu mehanizma upravljanja proizvodnjom za koji zaključuje da ima prednost i nad Kanban-om i nad CONWIP-om. Boonlertvanich objedinjuje neke značajke Kanban-a, CONWIP-a i stalnih zaliha (eng. *Base stock*) i uvodi novi mehanizam pod nazivom „Prošireni CONWIP - Kanban sustav“ (eng., *extended CONWIP - Kanban system*) [26].

Koliko je područje razvoja novih varijanti Kanban signalnog sustava bilo interesantno znanstvenicima i inženjerima govori i činjenica kako su do danas razvijene i analizirane trideset dvije različite varijante Kanban sustava, od toga devet varijanti je zaživjelo u praksi [27]. Također, do danas su razvijene četiri različite varijante CONWIP sustava [28].

Izbor odgovarajućeg mehanizma upravljanja proizvodnjom jako je bitan. U pojedinim proizvodnim uvjetima primjena jednog mehanizma biti će povoljnija u smislu postizanja što kraćeg ciklusa proizvodnje i što manje zaliha u procesu što je, zapravo osnovni cilj vitke proizvodnje, dok će u drugim uvjetima neki drugi mehanizam bolje funkcionirati. Na voditelju proizvodnje je donijeti odluku koji mehanizam primijeniti i definirati optimalne parametre odabranog mehanizma (ukupna količina zaliha u procesu, veličina Kanban kartice i sl.). No kako donijeti dobru odluku? Koji su to čimbenici koje treba uzeti u obzir pri odabiru

mehanizma upravljanja? Ukoliko proces nije stabilan, tj. varijabilnost pojedinih parametara je dosta visoka, da li će neki drug mehanizam više odgovarati nego mehanizam koji bi odgovarao u tom istom procesu ali sa malim varijacijama parametara. Prema Chao i Shih [29] postoji četrdeset i jedan parametar koji utječe na ponašanje proizvodnog procesa. Samo taj podatak govori o tome koliko je proizvodni proces kompleksan sustav i da definiranje mehanizma koji upravlja i kontrolira tijek materijala kroz takav sustav nije tako jednostavan zadatak.

Mnogi se autori bave utvrđivanjem optimalnih parametara pojedinih mehanizama, a zbog izrazito dinamičke prirode proizvodnog procesa unatrag nekoliko godina sve češće se koristi simulacijsko eksperimentiranje kako bi se dinamička priroda proizvodnog procesa što vjernije preslikala u model koji se analizira.

Kako se područje vezano za mehanizme upravljanja proizvodnjom sve više razvijalo tako se sve veći broj znanstvenika bavi njihovom usporedbom kako bi odgovorili na pitanje koji mehanizam više odgovara u specifičnim uvjetima proizvodnog procesa. Generalno sve radove koji se bave usporedbom mehanizama upravljanja proizvodnjom moguće je podijeliti u dvije skupine: istraživanja koja se bave proučavanjem proizvodnih procesa u kojima se izrađuje samo jedan proizvod [11], [12], [13], [14], [18], [15], [17], [21], te istraživanja koja se bave procesima u kojima se proizvodi dva ili više proizvoda [16], [19], [20].

Nedostatak većine usporedbi je nepostojanje unificiranog okvira za usporedbu. Naime, veliki broj istraživanja ne uzima u obzir optimalne parametre mehanizama koje uspoređuju [12]. Vjerojatno i zato postoje kontradiktorni zaključci. Tako na primjer Lavoie, Gharbi i Kenne [12] zaključuju da je u nekim situacijama Kanban bolji što je u suprotnosti sa Bonvikovim zaključkom [21]. Cheraghi et. al. napominju kako su Gastettner i Kuan analizirali Kanban i CONWIP te zaključili da se izborom najbolje distribucije Kanban kartica postiže manje zaliha u procesu nego kod CONWIP-a što je u suprotnosti sa Speramanovim radom [19], [22].

Da bi usporedba bila korektna Amos smatra da svaki od mehanizama treba imati optimalne postavke s obzirom na zadane kriterije, te tako predlaže metodologiju za usporedbu različitih mehanizama a koja se temelji na simulacijskom eksperimentiranju i višekriterijskom optimiranju [11].

Amos u svom radu uspoređuje Kanban, CONWIP te DBR (eng. *Drum Buffer Rope*) u proizvodnji jednog proizvoda. Simulirao je nebalansiranu proizvodnu liniju koja se sastoji od 14 radnih stanica te je eksperimentirao na način da je mijenjao mjesto uskog grla u procesu. Zaključak je da DBR generalno bolji od Kanban i CONWIP sustava [11].

Kao eksperimentalni faktor prilikom usporedbe dosta autora uzima količine zaliha u međuspremnicima, a što zapravo definira veličina signalnih kartica [12], [14], [18].

Lavoie, Gharbi i Kenne, prate kako se ponaša funkcija troškova za različite veličine međuspremnika i zaključuju da je hibridni mehanizam bolji od Kanban-a i CONWIPa ako se uzmu u obzir i troškovi prostora za odlaganje zaliha, no ako se ti troškovi ne uzmu u obzir već se samo promatraju troškovi držanja zaliha onda su hibridni mehanizam i CONWIP podjednako dobri. Kanban postaje financijski isplativiji ako se povećaju troškovi prostora držanja zaliha i broj operacija [12].

Količinu zaliha u međuspremnicima kao utjecajni faktor uzima i Pettersen, no učestalost zastoja strojeva uzima kao još jedan parametar koji utječe na izbor mehanizma. Pettersen uspoređuje Kanban i CONWIP, simulirajući proizvodnju jednog proizvoda na proizvodnoj liniji koja se sastoji od 4 radna mjesta i potvrđuje prednost CONWIP-a nad Kanban-om [13].

Problemom izbora mehanizma upravljanja proizvodnjom u procesu izrade jednog proizvoda bavili su se i Enns i Rogers [18], koji uspoređuje CONWIP i „push“ mehanizam, na način da u simulacijskom eksperimentu također mijenjaju razine zaliha u međuspremnicima, ali uzimaju u obzir i varijabilnost vremena obrade, te varijabilnost potražnje mijenjajući tempo pristizanja narudžbi. Na kraju ne daju jednoznačan zaključak koji bi mehanizam bio bolji u navedenim uvjetima u proizvodnji.

Bonvik kao i Enns i Rogers analizira proizvodnju jednog proizvoda u uvjetima različitih razina potražnje, uspoređujući Kanban, CONWIP i hibridni mehanizam te zaključuje da u većini slučajeva hibridni mehanizam daje bolje rezultate ako je cilj postići što manje zaliha u procesu i što bolju razinu usluge u smislu isporuke na vrijeme [21].

Sharma i Agrawal [15] su analizirali ponašanje proizvodnog sustava pod različitim mehanizmima (Kanban, CONWIP i hibridni), također u uvjetima promjenjive potražnje. Analizirana je proizvodna linija od četiri radne stanice i proizvodnja jednog proizvoda. AHP metodom dobiveni rezultati su rangirani i dobiveno je koje alternative više odgovaraju

obzirom na pojedini kriterij (minimalno zaliha u procesu, maksimalni tempo proizvodnje, itd.). Obzirom na zahtijevane kriterije određen je najbolji izbor mehanizma za različite režime potražnje (četiri različite statističke distribucije). Zaključak je da je Kanban bolji za tri distribucije, a CONWIP samo za jednu distribuciju [15].

Kabadurms [16] je simulacijskim eksperimentiranjem analizirao proces proizvodnje pet različitih proizvoda i došao do zaključka kako u uvjetima promjenjive potražnje POLCA sustav daje bolje rezultate u odnosu na CONWIP, ako je kriterij što manje zaliha u procesu i što kraći ciklus proizvodnje. Kabadurms je koristio faktorski plan pokusa mijenjajući 5 parametara: koeficijent varijacije trajanja operacija, vremenski razmak pristizanja narudžbi, veličina serije, broj zastoja u procesu, te varijacije proizvoda (mijenjao udio pojedinih proizvoda u procesu proizvodnje za određeno vremensko razdoblje). Ono što autor nije uzeo u obzir je vrijeme pripreme tj. namještanje stroja te varijabilnost istog što je jako bitan faktor koji utječe na efikasnost ova dva mehanizma.

Cheraghi [19] je također analizirao proizvodnu liniju na kojoj se proizvodi više tj. konkretno dva različita proizvoda. On je analizirao kako veličina serije, učestalost potražnje, te način održavanja strojeva utječu na ukupnu količinu zaliha u procesu i tempo proizvodnje. Zaključio je da učestalost potražnje značajno utječe na ponašanje PCM-ova, te također zaključuje da „pull“ proizvodnja nije uvijek najbolji izbor u odnosu na „push“ kad je riječ o kriteriju smanjenja ukupne količine zaliha u procesu.

U svojoj doktorskoj disertaciji Terrence [20] također analizira proizvodnju više različitih proizvoda na proizvodnoj liniji na način da uspoređuje Kanban sa Ekonomičnom serijom proizvodnje (eng- *Economic production quantity*, EPQ). Kriterij za usporedbu su zalihe u procesu, ciklus proizvodnje i ukupni troškovi proizvodnje, a analizira utjecaj vremena namještanja stroja. Terrence zaključuje kako vrijeme trajanja namještanja strojeva značajno utječe na troškove proizvodnje i u slučaju Kanban-a i u slučaju EPQ, na način da duže vrijeme namještanja stroja znači i veće troškove. Međutim u slučaju dužeg vremena namještanja stroja EPQ daje niže troškove nego Kanban. Djelomično je tome razlog i veće serije proizvodnje kod EPQ što zapravo smanjuje učestalost namještanja strojeva. Troškovi su niži u slučaju Kanban-a jedino kada je vrijeme namještanja kraće od 15min. Terrence na kraju zaključuje da je prednost Kanban-a što daje fleksibilnost proizvodnji, no ne uzima u obzir promjenjivost razine ili učestalosti potražnje što je jako bitan faktor, već potražnju drži konstantnom, a također ne uzima u obzir određene faktore koji značajno mogu utjecati na

ponašanje proizvodnog procesa ali i na odluku o izboru mehanizma upravljanja proizvodnjom (varijacije vremena trajanja operacija, zastoji u procesu i sl.) [20].

1.2 Cilj i hipoteza istraživanja

Cilj ovog rada jest analizirati kako promjena karakteristika proizvodnog procesa, te izbor mehanizma upravljanja proizvodnjom utječe na dvije mjerne performanse proizvodnog procesa a to su produktivnost i vodeće vrijeme. Cilj je utvrditi u kojim uvjetima određeni mehanizmi upravljanja proizvodnjom su bolji izbor obzirom na karakteristike proizvodnog procesa.

Hipoteza doktorske disertacije glasi:

- Izborom odgovarajućeg mehanizma upravljanja proizvodnjom kojim se postiže povlačenje materijala kroz proces moguće je optimalno unaprijediti performanse proizvodnog procesa.

1.3 Metodologija i plan istraživanja

Pri realizaciji dokorskog rada biti će provedeno istraživanje koje je moguće podijeliti u nekoliko temeljnih koraka.

U prvoj fazi istraživanja načinit će se detaljan pregled i analiza literature unutar predmetnog područja istraživanja. Također biti će pregledani i analizirani do sada objavljeni znanstveni radovi i doktorske disertacije koji obrađuju sličnu tematiku. Temeljem dobivenih spoznaja te korištenjem do sada stečenog znanja utvrdit će se koji parametri utječu na uspješnu primjenu mehanizama upravljanja u cilju primjene mehanizma povlačenja i unapređenja proizvodnog procesa. Također biti će utvrđeni parametri za praćenje uspješnosti vitkog proizvodnog procesa (metrika). Kroz pregled literature i publikacija biti će analizirani najčešće korišteni mehanizmi upravljanja proizvodnjom te će se utvrditi koji od njih se uspješno i najviše koriste u praksi, te temeljem navedenih spoznaja i vlastitog iskustva, te ideja definirat će se mehanizmi koji će biti analizirani u daljnjem istraživanju.

U drugoj fazi istraživanja metodom simulacije biti će modeliran proizvodni proces te uzimajući u obzir spoznaje dobivene u prvoj fazi istraživanja (izbor mehanizama upravljanja, izbor utjecajnih parametara, te izbor metrike) vršit će se simulacijsko eksperimentiranje s

ciljem analize utjecaja izbora mehanizma upravljanja proizvodnjom u različitim uvjetima u proizvodnji (različite razine utjecajnih parametara) na postavljeni kriterij (definiranu metriku za praćenje vitkog proizvodnog procesa).

U trećoj fazi istraživanja, analizirat će se rezultati simulacijskih eksperimenata, prikazat će se dobiveni rezultati te će se dati kritički osvrt i smjernice za donošenje odluka o izboru mehanizma upravljanja proizvodnjom ovisno o specifičnim uvjetima u proizvodnom procesu i postavljene kriterije.

Četvrta i posljednja faza istraživanja obuhvatila bi testiranje dobivenih rezultata na definiranom proizvodnom procesu.

1.4 Očekivani znanstveni doprinos

Znanstveni doprinos očekuje se u sljedećem:

- odredit će se utjecaj značajki proizvodnog procesa (varijabilnost vremena obrade, vrijeme trajanja operacije, postojanje uskog grla u procesu, broj upravljačkih kartica) te mehanizma upravljanja proizvodnjom na performanse proizvodnog procesa. Uzet će se u obzir mehanizmi upravljanja koji se koriste u praksi a koji do sada nisu zajedno istraženi u dostupnoj literaturi.

Dobivene spoznaje/znanja povezat će mehanizme upravljanja proizvodnjom sa karakteristikama proizvodnog procesa što će omogućiti lakše donošenje odluke o izboru mehanizma upravljanja proizvodnjom obzirom na postojeće karakteristike proizvodnog procesa u cilju primjene principa povlačenja i postizanja boljih performansi proizvodnog procesa.

2. VITKA PROIZVODNJA

Vitka proizvodnja (eng. *lean production*) je termin smišljen 80-tih godina prošlog stoljeća kojim je definirana Toyotina proizvodna filozofija. Vitka proizvodnja je način organiziranja i upravljanja proizvodnjom ali i poduzećem u cijelosti. Iako svoje korijene ima u proizvodnom sektoru, danas svoju primjenu Vitka proizvodnja ima i u uslužnim djelatnostima pa su tako smišljeni i novi termini kao što su „Vitke usluge“ (eng. *lean services*), „Vitko zdravstvo“ (eng. *lean healthcare*), „Vitka vlada“ (eng. *lean government*) „Vitko školstvo“ (eng. *lean university*).

2.1 Povijest Vitke proizvodnje

Od kako je knjiga *The Machine that change the world*, prije 20 godina pobudila veliki interes zapada za Toyotinu proizvodnu filozofiju, zanimanje i interes za japanski pristup organizaciji i upravljanju ne slabi [30]. Naprotiv, sve je više poduzeća koja shvaćaju da je usvajanje Toyotine proizvodne filozofije, odnosno principa Vitke proizvodnje, jedini put ka održivom poslovanju. Mnoge su implementacije principa Vitke proizvodnje bile jako uspješne i transformirale kompanije od sporo rastućih ili čak kompanija na rubu opstanka na tržištu, u kompanije koje su svojom učinkovitošću i efikasnošću opstale ili čak preuzele veći udio tržišta nego što je bila situacija prije usvajanja principa Vitke proizvodnje. No međutim, iskustva pokazuju da nisu sve implementacije Vitke proizvodnje tako uspješne. Puno je razloga za to. Jedan od njih je da Vitka proizvodna filozofija nije metodologija i alat koji se na jednak način može primijeniti u svakom poduzeću. Naprotiv, upravo takvi pokušaji „kopiranja“ uspjeha tuđih *lean* inicijativa završavaju u slijepoj ulici, što najčešće dovodi do odustajanja i paušalnog zaključka da primjena Vitke proizvodnja nije baš dobar za svako poduzeće. Naravno da je takav pristup pogrešan. U svom istraživanju pod nazivom „*Lean proizvodnja: uspješna implementacija novih pristupa organizaciji proizvodnje, umjesto kratkoročnih rezanja troškova*“, Thorsten Ahrens iz *Lean Alliance Germany*, dolazi do odgovora na pitanje koji su to kritični faktori za uspješnu implementaciju principa Vitke proizvodnje u poduzeća. Istraživanje je obuhvatilo 170 poduzeća koja su implementirala ili bila u fazi implementiranja *principa Vitke proizvodnje* u 23 države. Od 30 mogućih kritičnih faktora za uspješnost implementacije *principa Vitke proizvodnje* istraživanje je pokazalo da najveći utjecaj uspješnosti implementacije imaju dva faktora. Prvi faktor je podrška i odluka o

implementaciji od strane Uprave i top menadžmenta poduzeća, a drugi faktor je jako i snažno vodstvo u projektu implementacije[31].

Vitka proizvodnja je zapadnjački naziv za Toyotin proizvodni sustav. Naziv vitak (eng. *lean*) je skovao John Krafick, jedan od istraživača na projektu IMVP-a (*International Motor Vehicle Program*), sa *Massachusetts Institute of Technology* krajem 80-tih godina prošlog stoljeća, a prvi put je zaživio u knjizi *The Machine that change the world* [30]. Knjiga je bila rezultat navedenog istraživanja u kojoj su autori prvi put opisali razlike između japanske i zapadne automobilske industrije i prvi put upotrijebili izraz *lean* za Toyotin način proizvodnje. Takav način proizvodnje značio je manje svega: manje pogona, manje skladišta, manje vremena, manje ljudskog napora i investicija. Kako su konkretni rezultati od primjene Vitke proizvodnje bili sve očitiji tako se taj način proizvodnje počinje sve više primjenjivati i na zapadu, u početku naročito u SAD.

IMVP počeo je svoj istraživački rad započeo 1979. godine, nazvavši ga „Budućnost automobila“ (*The Future of the Automobile*). Program je osnovan na MIT-u (*Massachusetts Institute of Technology*) ali je od početka ideja bila stvoriti međunarodnu mrežu fakulteta i sveučilišta koji će obaviti istraživanja za IMVP. Tako su im se odmah u početku pridružili istraživači sa Harvarda, a poslije i Jim Womack, koji će u drugoj fazi programa postati direktor istraživanja u Europi. Svoju prvu knjigu, „Budućnost automobila“, su objavili u vrijeme kada je japanski izvoz postao velika briga zapadnim proizvođačima. „Budućnost automobila“ nije posebno istražio „japanski fenomen“ organizacije proizvodnje osim što su ga ponegdje spomenuli. No knjiga je izazvala pažnju i sponzori su „ohrabrili“ istraživački tim da nastavi proučavati japanski uspjeh.

Godine 1984. otvoren je zajednički pogon (joint venture) General Motorsa i Toyote, NUMMI (*New United Motor Manufacturing*). Pod Toyotinim vodstvom NUMMI je ostvario zavidne rezultate: broj uložених radnih sati po jednom vozilu sa 36 smanjen je na 19 sati. Škart je pao sa 1,5 na 0,5 na 100 komada. Broj izostanaka sa posla smanjen je sa 15% na 5%. Dvije godine kasnije John Krafick objavljuje studiju „*Learning from NUMMI*“. Ta studija je imala snažan utjecaj na kompanije koje su poticale i sponzorirale daljnji rad i istraživanje IMVP-a.

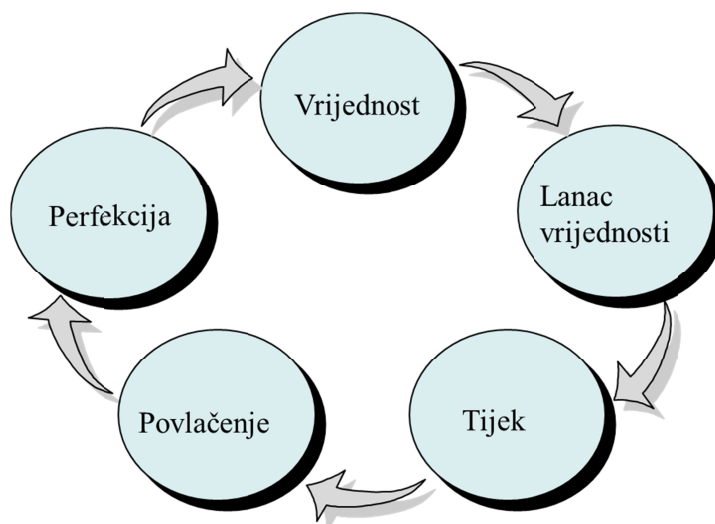
Od izlaska knjige *The Machine that change the world* do danas primjena Vitke proizvodnje je zahvatila, može se reći, cijeli planet, te je globalno raširena paradigma kada je

riječ o unapređenju poslovanja poduzeća. Dakako, cijela priča je krenula iz automobilske industrije, dakle iz proizvodnih pogona, no danas se ovaj pristup koristi i primjenjuje u svim sektorima, od uslužnih do proizvodnih, pa se tako Vitka proizvodnje danas primjenjuje u bolnicama i općenito u zdravstvu, u javnoj upravi u vladinim institucijama, itd. Zajednički nazivnik svim ovim područjima primjene principa Vitke proizvodnje, jeste da se koristi procesni pristup, te da se želi iz procesa ukloniti ili smanjiti sve ono što ne stvara vrijednost, odnosno što je gubitak. To je i suština principa Vitke proizvodnje: prepoznati, smanjiti i eliminirati gubitke u procesu stvaranja vrijednosti za kupca.

2.2 Principi Vitke proizvodnje

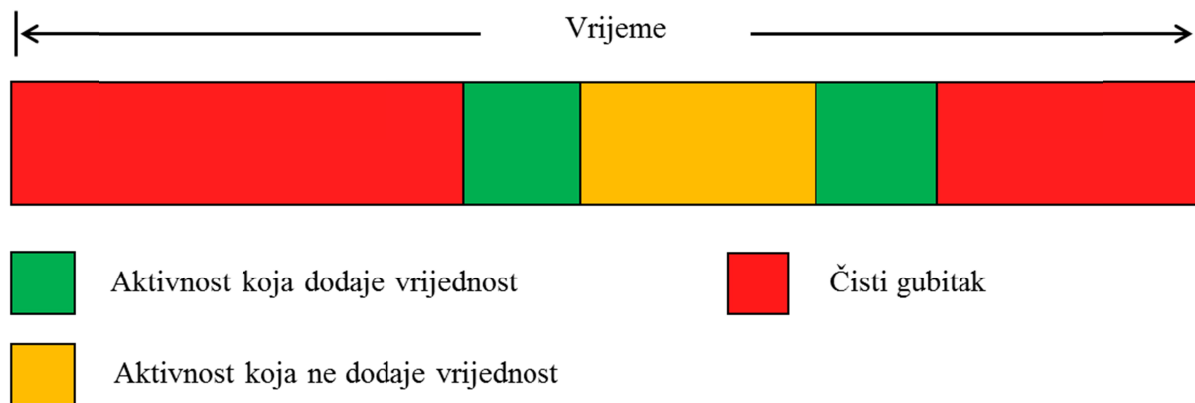
U knjizi *Lean thinking* Womack, J. P. and Jones, D.T definiraju pet osnovnih principa Vitke proizvodnje (slika 1), [2]:

1. Vrijednost – definirati vrijednost
2. Lanac vrijednosti – identificirati lanac vrijednosti
3. Tijek – neka vrijednost kontinuirano teče
4. Povlačenje – neka kupac povlači vrijednost
5. Perfekcija – težiti perfekciji kroz kontinuirana poboljšanja



Slika 1. Pet principa Vitke proizvodnje

Princip „vrijednost“ je polazište filozofije Vitke proizvodnje. Vrijednost se definira i opisuje iz perspektive kupca tj. kako je vidi i zahtijeva kupac. Vrijednost se opisuje kroz definiranje specifičnosti proizvoda ili usluge uz određenu cijenu i za određenog kupca. Vrijednost se, također, definira i kroz prizmu promatranja aktivnosti kao aktivnosti koje dodaju vrijednost proizvodu, aktivnosti koje ne dodaju vrijednost proizvodu i aktivnosti koje su čisti gubitak (slika 2).



Slika 2. Aktivnosti u proizvodnom procesu


Princip „lanac vrijednosti“ promatra proizvodni proces kao skup povezanih aktivnosti, funkcija i procesa potrebnih kako bi se od sirovine dobio gotov proizvod. Lanac vrijednosti je zapravo tijek vrijednosti, a u Toyoti su još 50-tih godina prošlog stoljeća razlikovali tri različita tijeka vrijednosti. Prvi od njih je tijek materijala. Razumljivo, tu se podrazumijeva tijek obratka kroz sam proces proizvodnje gdje u etapama taj obradak, odnosno materijal mijenja svoj izgled do konačnog oblika tj. gotovog proizvoda. Druga vrsta tijeka bi bila tijek informacija. Tijek informacija je jednako bitan tijek vrijednosti u proizvodnom procesu a može se slobodno reći i značajniji, jer upravo tijek informacija diktira kako će se kretati materijal kroz proizvodni proces. Treći, ne manje bitan tijek vrijednosti kroz proizvodni proces je tijek ljudi, tj. ljudskog resursa. Raspored radnika po radnim mjestima, rotacija radnika između pojedinih operacija, opsluživanje jednog radnika više strojeva istovremeno itd., sve to direktno, poput tijeka informacija utječe na onaj bazni tijek u proizvodnom procesu a to je tijek materijala. Također, tijek informacija i tijek ljudi imaju sasvim drugo značenje i važnost u uslužnim djelatnostima ili u procesu razvoja proizvoda, konstruiranju itd. Predmet ovog istraživanja je upravo tijek informacija u proizvodnom procesu te kako on utječe na mjerne performanse proizvodnog procesa.

Princip „tijek“ podrazumijeva proizvodni proces u kojem su eliminirani zastoji, neplaniran rad i sve ono što zaustavlja i narušava tijek materijala od ulaza u proizvodni proces do izlaska iz proizvodnog procesa. Reduciranje aktivnosti koje ne dodaju vrijednost i aktivnosti koje su gubitak nužno je za stvaranje tijeka. Jedan od uvjeta stvaranja tijeka je uvođenje tijeka jednog komada (eng. *one piece flow*) kako bi se eventualni problemi i greške na vrijeme otkrili i kako bi se izbjegle serijske greške te zastoji koji povlače za sobom puno veće vremenske gubitke (dorado cijele serije ili ponovna izrada cijele serije) kao i puno veće gubitke materijala što u konačnici značajno povećava trošak proizvoda. U slučaju tijeka jednog komada greške se lakše uočavaju, nisu sustavne u smislu da zahvate cijelu seriju i lakše i brže ih je moguće ispraviti kako bi se proces vratio svom planiranom tijeku. U tu svrhu u Toyoti su razvili niz alata za lako uočavanje i otklanjanje grešaka kao što je Andon, Poka-yoke i drugi. Predmet istraživanja u ovoj disertaciji će biti proizvodni proces kojem je značajka tijek jednog komada.

Princip „povlačenje“ jedan je od najvažnijih principa Vitke proizvodnje. Povlačenje znači da nitko u procesu ne proizvodi dalje dok kupac nije povukao proizvod. U tom smislu, kupcem se smatra svaka etapa proizvodnog procesa. Tako, ukoliko stroj ili radna stanica u etapi broj dva nije zatražio proizvod od prethodne etape, dakle nije povukao proizvod, etapa broj jedan ne proizvodi dalje. I tako se cijeli val povlačenja širi kroz proizvodnju uzvodno od krajnjeg kupca pa sve do početka proizvodnog procesa. Područje istraživanja u ovoj disertaciji biti će princip povlačenja, posebno njegova implementacija u proizvodnom procesu pomoću različitih mehanizama upravljanja proizvodnjom.

Princip „perfekcija“ govori o potrebi za stalnim, kontinuiranim unapređenjem proizvodnog procesa. U Toyoti su još davno primijenili ovaj način razmišljanja. Njihova je premisa bila da svakodnevne male promjene daju u konačnici veća poboljšanja koje je lakše zadržati nego što je to slučaj sa velikim i rjeđim projektima poboljšanja koji podrazumijevaju velike zahvate i rekonstrukcije koje vrlo često kasnije nije moguće održati.


Guranje proizvodnje (eng. *push production*) se povezuje sa MRP-om. MRP je skraćenica od engleskog naziva „*Material Requirements Planning*“, poznata kao metodologija „Planiranje potrebe za materijalom“ kojom se pomoću računalnih programa određuju proizvodne količine, te termini početka i završetka proizvodnje. Napredna verzija ove metodologije, poznata pod nazivom „*Manufacturing Resource Planning*“ uzima u obzir i opterećenje kapaciteta, radne snage itd. Kako Hopp i Spearman objašnjavaju, „*push* sustav“ zasnovan na MRP-iju pušta materijal u proizvodnju temeljem iscrpnog planiranja koje može biti temeljeno bilo na prognozi potražnje, bilo na stvarnoj potražnji, ali ne uzima u obzir stvarno trenutno stanje u sustavu. Kod *push* sustava nema specifičnog ograničenja na količinu rada u procesu (eng. *work in process* - WIP). Jedini način za kontrolu rada u procesu jeste kontrola broja radnih naloga, a time i količine materijala, koji ulaze u proizvodni sustav. Slika 3 prikazuje *push* proizvodni sustav.



Slika 3. *Push* sustav

U osnovi, tijek materijala i tijek informacija u *push* proizvodnom sustavu imaju isti smjer. Informaciju o potražnji kupca, tj. o tome što treba proizvesti, dobije svako radno mjesto zasebno. Svako radno mjesto, odnosno svaka radna stanica ili obradni centar dobiva zasebne radne naloge. Prema specifikacijama iz radnog naloga prije svega prema podacima što treba proizvesti i kada započeti proizvodnju to određeno radno mjesto proizvodi. Što se događa na prethodnim radnim mjestima i mjestima koja slijede, određeno radno mjesto nema informaciju, te funkcionira kao zasebna karika u proizvodnom lancu koja proizvodi temeljem naloga koji je dobila. U slučaju bilo kakvih poremećaja uzvodno ili nizvodno u proizvodnom procesu, npr. u slučaju zastoja na nekom od slijedećih radnih mjesta, ta određena radna stanica nema informaciju, te nastavlja sa proizvodnjom skoro nezavisno.

Način na koji se informacija za pokretanje proizvodnje distribuira prema radnim mjestima je ključna razlika između *pull* i *push* proizvodnog sustava. [32]. U *pull* sustavu materijal dolazi na obradu na određeno radno mjesto ovisno o stanju u cijelom proizvodnom sustavu. Materijal nije guran dalje na iduće radno mjesto kada je obrada na trenutnom radnom mjestu završena, već je okidač za daljnji tijek materijala stvarna potražnja nizvodno niz proizvodni proces (Slika 4).

Slika 4: *Pull* sustav

Autori Hopp i Spermann naglašavaju da je fundamentalna razlika između *push* i *pull* proizvodnog sustava u tome da *pull* proizvodni sustav eksplicitno ograničava količinu rada u

procesu [5]. To implicira da *push* proizvodni sustav ne ograničava eksplicitno količinu rada u procesu. Upravo je ovo, prema Hopp i Sperman, temeljna razlika između *pull* i *push* proizvodnog sustava. Kako autori navode, nakon izlaska knjige Lean thinking [2] i njihove definicije što je to *pull* proizvodnja a koja glasi - „Najjednostavnije rečeno *pull* znači da nitko uzvodno u procesu ne smije proizvoditi proizvod ili uslugu dok kupac nizvodno to ne traži“ – uvriježilo se mišljenje da je *pull* proizvodnja ekvivalent za proizvodnju prema narudžbi (eng. make-to-order) što, kako Hopp i Sperman objašnjavaju, nikako nije slučaj. Proizvodnja planirana putem MRP-a također može biti proizvodnja prema narudžbi, a sam proizvodni sustav nije *pull*. Spomenuti autori dali su definiciju *pull* sustava a koja daje jasniju sliku koja je to temeljna razlika između *pull* i *push* proizvodnog sustava. Definicija glasi:

„*Pull* proizvodni sustav direktno ograničava količinu rada u procesu. To onda povlači da je *push* proizvodni sustav takav da ne ograničava eksplicitno količinu rada u procesu [5].“

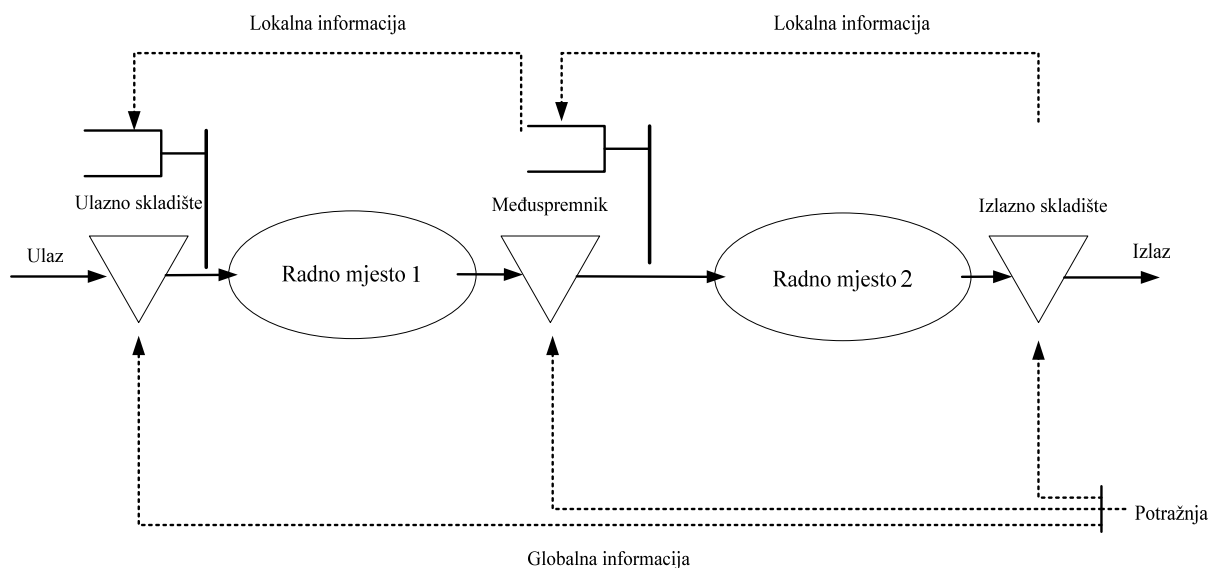
Prema Hopp i Spearman princip povlačenja (eng. *pull principle*) se često poistovjećuje sa Kanban-om, međutim Kanban je samo sredstvo za postizanja principa povlačenja. Kanban je mehanizam upravljanja proizvodnjom kojim se postiže *pull* proizvodnja, a osmišljen j, upravo u Toyotinim pogonima gdje je i samo mjesto razvoja principa Vitke proizvodnje pa i *pull* sustava.

U narednom poglavlju diskutirani su i objašnjeni mehanizmi upravljanja koji će biti istraženi u ovom doktorskom radu.

3.1 Mehanizmi upravljanja proizvodnjom

Proizvodni sustav je složena mreža strojeva, radnika i drugih resursa. Efikasan proizvodni sustav je onaj sustav koji proizvodi točno traženi proizvod u točno određeno vrijeme po najpovoljnijoj cijeni [31]. Proizvodni proces je moguće promatrati kao tijek materijala i kao tijek informacija. Tijek informacija u proizvodnom procesu može biti globalni i lokalni. Pod globalnim tijekom informacija podrazumijeva se informacija o potražnji, odnosno informacija o narudžbi kupca. Ova informacija može biti proslijeđena samo u jednoj točki (fazi) proizvodnog procesa ali može biti i distribuirana svim pojedinim fazama (radnim mjestima) proizvodnog procesa, neovisno. Lokalna informacija sasvim suprotno, podrazumijeva komunikaciju između pojedinih faza (radnih mjesta) proizvodnog

procesa (slika 5). Lokalna informacija prenosi stanje pojedinih faza proizvodnje, dakle predstavlja međukomunikaciju unutar samog proizvodnog sustava.



Slika 5. Globalni i lokalni tijek informacija u proizvodnom procesu [31]

Mehanizmi upravljanja proizvodnjom (eng. *production control mechanisms*) definiraju tijek informacija i logiku kojom oni upravljaju tijekom materijala u tvornici [17]. Dakle, fokus je na tijeku informacija koji kontrolira tijek materijala a ne na samo fizičko kretanje materijala u proizvodnom procesu.

Bicheno navodi, Kanban je samo jedan od tri najčešće primjenjivanih metodologija (mehanizama upravljanja proizvodnjom) za postizanje *pull* sustava. Druga dva najčešće primjenjivana mehanizma su CONWIP (eng. *Constant work in process*) i DBR (eng. *Drum buffer rope*) [33].

U literaturi se navode i drugi mehanizmi upravljanja. Hibrid Kanban/Conwip mehanizam upravljanja je jedan od njih, te je odlučeno kako će predmet istraživanja ovog rada biti slijedeći mehanizmi upravljanja proizvodnjom:

1. Kanban
2. Conwip
3. Hibrid Kanban/Conwip
4. DBR.

3.1.1 Kanban

Kanban je jedan od najpoznatijih i najčešće primjenjivanih mehanizama upravljanja proizvodnjom kojim se upravlja povlačenjem materijala u proizvodnom procesu.

Postoje nekoliko različitih varijanti Kanban mehanizma. Na primjer, postoji Kanban mehanizam sa jednom karticom, ili Kanban mehanizam sa dvije kartice itd. U ovom radu razmatrat će se jednostavan Kanban mehanizam sa jednom karticom.

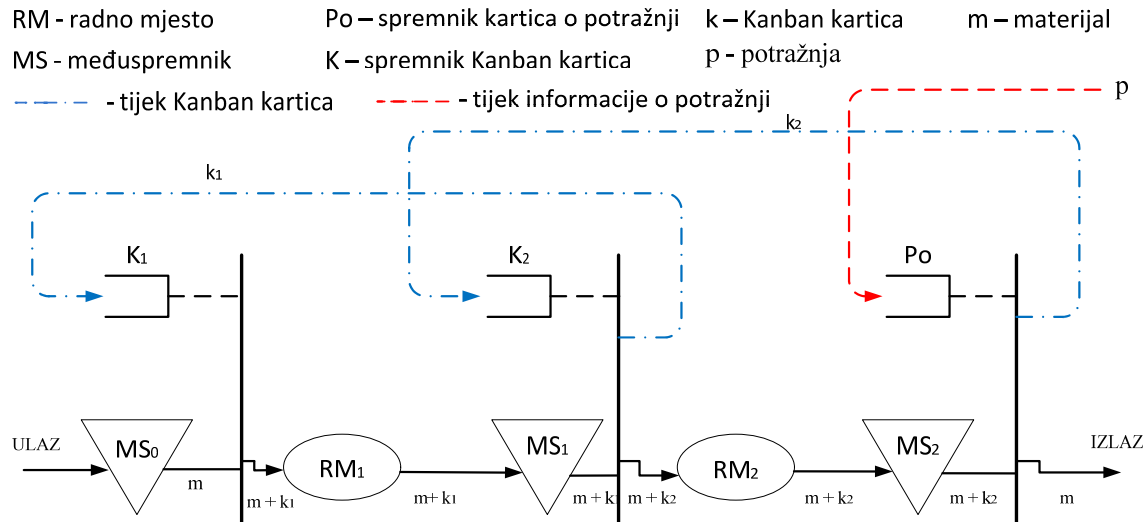
Na slici 6 je prikazana shema proizvodne linije koja se sastoji od dva radna mjesta (dvije etape proizvodnog procesa) gdje je proces upravljan jednostavnim Kanban mehanizmom upravljanja.

U početnom stanju u i -toj etapi proizvodnog procesa međuspremnik MS_i sadrži k_i poluproizvoda, gdje svaki poluproizvod ima pridružen jedan Kanban. Kada stigne potražnja od strane kupca, zahtjev ide u red Po i povlači gotov proizvod iz MS_2 . U tom trenutku postoje dvije mogućnosti:

- Ako postoji gotov proizvod u MS_2 , on se prosljeđuje kupcu nakon što se od njega odvoji Kanban k_2 koji mu je ranije pridružen. Taj Kanban se prebacuje u red K_2 što je signal za proizvodnju novog komada gotovog proizvoda u etapi 2.
- Ako ne postoji gotov proizvod u MS_2 , zahtjev se povlači i stavlja na čekanje sve dok gotov proizvod ne stigne u MS_2 . Čim gotov proizvod stigne, isporučuje se kupcu a Kanban ide u K_2 .

Kada Kanban kartica stigne u K_2 ona autorizira pokretanje proizvodnje novog komada u etapi 2. Ovdje se, ponovno, mogu dogoditi dvije situacije:

- Ako je u međuspremniku MS_1 raspoloživ poluproizvod (obradak) odmah se sa njega skida Kanban etape 1 i pridružuje mu se Kanban etape 2. Zatim, obradak i Kanban etape 2 idu zajedno na radno mjesto 2. Kanban etape 1 se prebacuje u K_1 što autorizira pokretanje proizvodnje na radnom mjestu 1.
- Ako u međuspremniku MS_1 nije raspoloživ poluproizvod (obradak) Kanban etape 2 čeka i K_2 sve dok novi obradak ne stigne u međuspremnik MS_1 .



Slika 6. Kanban mehanizam upravljanja proizvodnjom [26]


Na ovaj se način informacija o potražnji kupca, putem Kanban kartice, prenosi kroz proizvodni proces, suprotno od smjera proizvodnje. Ako u nekoj etapi i proizvodnog procesa nije dostupan obradak i u međuspremniku MS_i , Kanban kartica ne ide dalje uzvodno i tu je informacija o potražnji privremeno stopirana. Tako sve prethodne etape u proizvodnom procesu ne proizvode dok od etape koja slijedi nakon njih ne dobiju informaciju o potražnji.

Kanban je jednostavan mehanizam upravljanja proizvodnim procesima. Proizvodni proces ovisi samo o jednom parametru a to je broj Kanban kartica. Količina materijala u procesu ovisi isključivo o broju i veličini Kanban kartice. Veličina Kanban kartice predstavlja broj komada tj. veličina serije koja se transportira između pojedinih etapa procesa. U ovom radu razmatrat će se jednokomadna proizvodnja, što znači da je veličina Kanban kartice jednaka jedan.

3.1.2 Conwip

Conwip je mehanizam upravljanja proizvodnjom koji upravlja ukupnom količinom rada u procesu za cijeli proizvodni proces. Proizvodni proces je upravljan pomoću jedne Conwip kartice. Kada je prethodno definirana količina rada u procesu dosegnuta privremeno se zaustavlja ulazak novog materijal u proces dok idući materijal (gotov proizvod) ne izađe iz procesa.

Slika 8 pokazuje shematski prikaz modela upravljanja pomoću Conwip kartice. Ovdje je, ponovno, prikazan model sa dva radna mjesta tj. sa dvije etape. Međuspremnik između etapa, za razliku od Kanban sustava, ne igra nikakvu ulogu u upravljanju.



Slika 7. Conwip mehanizam upravljanja [26]

U početnom stanju međusprennik MS_2 sadrži količinu C gotovih proizvoda kojima je pridružena Conwip kartica. Kad pristigne potražnja kupca zahtjeva se od sustava isporuka gotovih proizvoda iz MS_2 . U tom trenutku postoje dvije mogućnosti:

- ako je dio dostupan u MS_2 odmah je isporučen kupcu, a Conwip kartica se skida sa proizvoda i šalje u red C
- ukoliko dio nije dostupan potražnja se stavlja na čekanje dok gotov proizvod ne bude dostupan u MS_2

Za ostale etape u proizvodnom procesu vrijede ista pravila kao i u *push* sustavu, nema zaustavljanja.

Conwip upravljanje je vrlo jednostavan sustav upravljanja. Ovisi samo o jednom parametru a to je veličina Conwip kartice. Veličina Conwip kartice predstavlja ukupnu

U početnom stanju skladište MS₂ sadrži gotove proizvode, tj. proizvode obrađene na radnom mjestu dva, odnosno u etapi 2. Proizvodi imaju pridružene i Kanban kartice etape 2 te Conwip kartice. U redu K₁ postoji količina „k“ kartica. Pretpostavlja se da je zbroj svih Kanban kartica veći ili jednak razini Conwipa.

Kanban/Conwip upravljanje funkcionira na slijedeći način. Kada se dogodi potražnja kupca, narudžba stiže u red P sa zahtjevom da izuzme gotov proizvod iz skladišta MS₂. U tom trenutku postoje dvije mogućnosti:

- ako je gotov proizvod dostupan isporučuje se kupcu nakon što je sa njega skinuta Kanban i Conwip kartica. Kanban kartica se prebacuje u red K₂ što je signal za proizvodnju novog gotovog proizvoda, a Conwip kartica se prebacuje u red C što je signal za puštanje nove količine materijala (sirovine, dijelova...) u proizvodnju.
- ako gotov proizvod nije dostupan narudžba se stavlja na čekanje u red P, dok etapa 2 ne završi obradu gotovog proizvoda.

Kada Kanban kartica stigne u red K₂ postoje dvije mogućnosti:

- ako postoji obradak u međuskladištu MS₁ sa njega se odmah skida (odvaja) Kanban kartica etape 1 i dodjeljuje mu se Kanban kartica etape 2. Obradak, zajedno sa Kanban karticom ide na radno mjesto RM₂. Kanban etape 1 ide u red K₁ što je signal za proizvodnju novog obratka (dijela, komada)
- ako obradak u međuskladištu MS₂ nije dostupan Kanban kartica etape 2 ide u red K₂.

3.1.4 DBR – *Drum-buffer-rope*

Bubanj-međuspremnik-uže, DBR, skraćenica od eng. *Drum – Buffer - Rope* je mehanizam upravljanja proizvodnjom koji su prvi osmislili, objasnili i primijenili Goldratt i Coxh kao dio svoje metodologije Teorija ograničenja (eng. *Theory of constraints*) [22]. U ovom radu, radi jednostavnosti biti će korištena skraćenica DBR. Prema toj metodologiji samo intervencija na ograničenju u sustavu će imati značajan utjecaj na cijeli sustav. Ograničenje je ovdje definirano kao resurs sa najvećom iskoristivošću kapaciteta. To je radno mjesto koje predstavlja usko grlo.

U početnom stanju međuspremnik MS_2 sadrži količinu N gotovih proizvoda. Kad pristigne potražnja kupca zahtjeva se od sustava isporuka gotovih proizvoda iz MS_2 . U tom trenutku postoje dvije mogućnosti:

- ako je dio dostupan u MS_2 odmah je isporučen kupcu, sa radnog mjesta RM_2 u međuspremnik pristiže novi proizvod „DBR“ kartica se skida sa proizvoda i šalje u red DBR
- ukoliko dio nije dostupan potražnja se stavlja na čekanje dok gotov proizvod ne bude dostupan u MS_2


Za ostale etape u proizvodnom procesu vrijede ista pravila kao i u *push* sustavu, nema zaustavljanja.

4. USPOREDBA MEHANIZAMA UPRAVLJANJA PROIZVODNOM PRIMJENOM SIMULACIJE

U ovom poglavlju metodom simulacije, odnosno simulacijskim eksperimentiranjem biti će uspoređeni mehanizmi upravljanja opisani u poglavlju 3. Cilj je na jednom modelu simulirati proizvodni proces upravljan sa svakim od četiri opisana mehanizma zasebno, te ih usporediti kroz praćenje mjera performansi proizvodnog procesa: produktivnost i vodeće vrijeme.

4.1 Opis simulacijskog modela

Model korišten za istraživanje utjecaja parametara proizvodnje na odabir mehanizma povlačenja materijala u proizvodnom procesu preuzet je iz rada „*Clarifying CONWIP versus PUSH system behavior using simulation*“ [18]. Model predstavlja proizvodnu liniju koja se sastoji iz pet radnih mjesta. Svako radno mjesto je druga proizvodna operacija. Između svake operacije nalazi se međuspremnik u koji se odlažu poluproizvodi nakon obrade na pripadajućoj operaciji. Dakle postoje četiri takva međuspremnika (slika 10). Pregledom literature utvrđeno je kako je proizvodna linija od 5 radnih mjesta dovoljna za obuhvatiti različite aspekte proizvodnje te relacije i probleme koji se javljaju u proizvodnom procesu [20], [34], [35], [36].



Slika 10: Proizvodni proces

Proizvodni proces započinje na radnom mjestu 1 i redom se nastavlja na radnim mjestima 2, 3, 4, i 5. Vrijeme obrade na svakom stroju iznosi 1 minuta a kako sam utro navodi simulacijski model je dovoljno fleksibilan da se u njega može uključiti i usko grlo. Vrijeme obrade korišteno u ovoj simulacijskoj studiji iznosi 5, odnosno 60 minuta. Također, uvedeno

je postojanje uskog grla na radnom mjestu 4. U slučaju postojanja uskog grla vrijeme trajanja operacije iznosi 6,67min (kada je vrijeme obrade na ostalim operacijama 5minuta), odnosno 80 min (kada je vrijeme obrade na ostalim operacijama 60 minuta). Za generiranje vrijednosti vremena trajanja obrade korištena je log-normalna distribucija. Pregledom literature ali i iz razgovora sa stručnjacima koji se bave ovim područjem utvrđeno je da log-normalna distribucija dobro opisuje pojavu vrijeme trajanja operacije. Za svako pokretanje simulacije korištenoj je novo sjeme slučajnog broja. Tako je osigurana slučajnost generiranih vrijednosti. Za svaku razinu tj. kombinaciju ulaznih parametara izvođeno je pet pokretanja simulacije (pet ponavljanja).

Za model su usvojene slijedeće pretpostavke:

- svaki stroj može obrađivati samo jedan proizvod u određenoj vremenskoj jedinici
- transport obrađenih dijelova iz međuspremnika na iduće radno mjesto slijedi pravilo *FIFO* (eng. *first-in-first-out*)
- vrijeme transporta između operacija je zanemarivo
- vrijeme prijenosa Kanban kartica, Conwip kartica, DBR kartica te informacija o potražnji je zanemarivo
- proizvodnja je organizirana kao tijek jednog komada
- Kanban mehanizam upravljanja je jednokartični Kanban
- vrijeme namještanja stroja nije predmet ovog istraživanja pa proizvodna linija proizvodi jednu vrstu proizvoda
- ulazno skladište nikada ne ostaje bez materijala
- vrijeme trajanja simulacije je 117 000 sati (odgovara jednoj godini)
- eventualna dorade, zastoji stroja, čekanje na radnika ili informaciju, te druge situacije koje mogu utjecati na varijabilnost vremena obrade, su „pokrivenne“ slučajnošću varijable vrijeme obrade
- obzirom da predmet istraživanja nije utjecaj vremena namještanja stroja, to vrijeme je uključeno u vrijeme obrade

4.2 Validacija simulacijskog modela

Kako je model preuzet iz drugog znanstvenog rada na početku je bilo potrebno validirati izrađeni model. Za validaciju su korištene dvije tehnike. Prva je usporedba sa već postojećim validiranim modelom (eng. Comparison to other models) a druga tehnika je postavljanje graničnih uvjeta (eng. extreme condition tests) [37]. U prvom dijelu simulacijske studije su simulirani procesi upravljani *push* principom te povlačenjem materijala Conwip mehanizmom upravljanja pod istim uvjetima kako je to načinjeno u spomenutom radu. Simulacijski model je izrađen u programskom paketu *Matlab*. Korišten je Simulink, posebni modul programskog paketa *Matlab* namijenjen za simulaciju, te dodatak za diskretnu simulaciju, *SimEvents* [38]. Zatim je izvršena usporedba dobivenih rezultata.

Zatim su modelirani i ostali mehanizmi upravljanja proizvodnjom, redom Kanban, hibridni Kanban/Conwip mehanizam, te DBR mehanizam upravljanja. Za validaciju ovih modela korištena je face validacija, te validacija pomoću graničnih vrijednosti na način da su mijenjane ulazne varijable od jedne do druge ekstremne vrijednosti i promatran je efekt tih ekstremnih (graničnih) vrijednosti.

Za slučaj *push* upravljanja i upravljanja Conwip mehanizmom vrijeme jednog pokretanja simulacije iznosilo je 101000 minuta, kako su to činili i autori u spomenutom radu. Pokretanje simulacije je ponavljano pet puta jednako kao u spomenutom radu. Kad je proizvodni proces završen gotov proizvod izlazi iz sustava. Potražnja je neograničena pa nema skladišta gotovih proizvoda. Ove pretpostavke o procesu su u skladu sa pretpostavkama koje su koristili i drugi autori u sličnim studijama [5], [39].

Vrijeme obrade je stohastičko i određeno je vremenom trajanja operacije i koeficijentom varijacije c_p , pri čemu je koeficijent varijacije omjer standardne devijacije vremena trajanja operacije i srednje vrijednosti (očekivane vrijednosti) vremena trajanja operacije, $1/\mu$. Razdioba korištena za generiranje vrijednosti vremena obrade je gama razdioba. Gama razdioba je određena parametrima α i β . Vrijednost α je jednaka $1/(c_p^2)$ a vrijednost β je jednaka c_p^2/μ . Ako je vrijednost koeficijenta varijacije, c_p , jednaka jedan, onda vrijednosti vremena obrade slijede negativnu eksponencijalnu razdiobu. Vrijeme obrade, μ , iznosi 1 minutu.

U slučaju *push* upravljanja definiran je tempo pristizanja materijala u sustav a on iznosi 1,67 min/kom slijedeći Poissonovu razdiobu. Praćene su dvije izlazne veličine: vodeće vrijeme i ukupan rad u procesu. Vodeće vrijeme je ukupno vrijeme od trenutka dolaska materijala na stroj 1 do trenutka kada gotov proizvod izlazi iz proizvodnje kupcu. Ukupan rad u procesu je ukupan broj obradaka koji se nalaze prosječno u svakom trenutku u procesu. Na kraju su izračunate prosječne vrijednosti navedenih veličina te uspoređene sa vrijednostima koje su dobili autori u spomenutim radu (tablica 1).

Tablica 1. Validacija simulacijskog modela – *push*

	Rezultati simulacije (Matlab)	Rezultati – Enns i Rogers [18]	Razlika	Razlika, [%]
Vodeće vrijeme [min]	12,48	12,384	0,096	0,775
Rad u procesu [kom]	7,6	7,465	0,135	1,8

U slučaju Conwip mehanizma upravljanja na početku simulacije je određen parametar C, a što predstavlja ukupan broj Conwip kartica u procesu. Kako je svaka pojedina Conwip kartica vezana na jedan obradak onda je to i ukupan broj obradaka, odnosno rada u procesu (WIP). Broj kartica iznosi 6. Promatrane su veličine: vodeće vrijeme i propusnost. Simulacija je ponavljana pet puta kao i u prethodnom slučaju, te su izračunate prosječne vrijednosti navedenih promatranih veličina. Dobiveni rezultati su uspoređeni sa rezultatima dobivenim u članku Ennsa i Rogersa (tablica 2).

Tablica 2. Validacija simulacijskog modela – Conwip

	Rezultati simulacije (Matlab)	Rezultati – Enns i Rogers [18]	Razlika	Razlika, [%]
Vodeće vrijeme [min]	10,14	9,925	0,215	14
Propusnost [kom/min]	0,618	0,605	0,013	2,1

Obzirom da su odstupanja prikazana u tablici 1 i 2 neznatna može se zaključiti da simulacijski model dobro oponaša model iz članka „*Clarifying CONWIP versus PUSH system behavior using simulation*“, [18], tj. zadovoljava validaciju.

4.2.1 Validacija Kanban modela

Na već postojećem, validiranom simulacijskom modelu proizvodnog procesa, modeliran je Kanban mehanizam upravljanja. Kako bi Kanban simulacijski model bio validiran uvedene su određene izmjene u modelu koje očekivano trebaju dati ekstremno drugačiji rezultat. Prvo je izmijenjeno vrijeme trajanja obrade na drugom stroju. Postavljeno je vrijeme koje iznosi 80% ukupnog vremena izvođenja simulacije, dakle ekstremno dugo vrijeme trajanja obrade. Sada vrijeme trajanja operacije na drugom stroju iznosi 85 000 minuta. Kako je ukupno vrijeme trajanja simulacije 117 000 minuta proces koji ima operaciju sa tako dugim vremenom trajanja jedne od operacija ne bi trebao proizvesti više od jednog komada. U idealnim uvjetima, u periodu od 117 00 minuta proces bi trebao moći proizvesti 1950 komada. Dobiveni rezultati odgovaraju očekivanom i dani su u tablici 3.

Tablica 3. Validacija Kanban modela – prvi granični uvjet

	Produktivnost – idealno [kom]	Produktivnost – $t_2=85\ 000\text{min}$, [kom]
Kanban model	1950	1

Drugi granično postavljen uvjet je broj Kanban kartica na zadnjem stroju i on je zadan da bude jednak nuli. Sustav nije ništa proizveo jer nema mehanizma (Kanban kartice) koji bi prenosio informaciju uzvodno. Postavljanjem i ovog graničnog uvjeta dobiveni rezultati daju zaključiti da Kanban mehanizam u ovom modelu dobro funkcionira.

Tablica 4. Validacija Kanban modela – drugi granični uvjet

	Produktivnost – idealno [kom]	Produktivnost – nema kanabna kartice na zadnjem stroju, $K_5=0$ [kom]
Kanban model	1950	0

4.2.2 Validacija Conwip modela

Prvi granični uvjet kojim je provjerena valjanost Conwip modela bio je broj Conwip kartica. Conwip kartice su mehanizam prijenosa informacija o potražnji, te se putem njih pokreće proizvodnja novog proizvoda. Ukoliko se u simulacijskom modelu postavi da je njihov broj jednak nuli, sustav ne bi trebao proizvesti niti jedan proizvod jer naprosto nema prijenosa informacije o pristizanju narudžbi tj. o potražnji kupca. Kako je i očekivano, nakon što je u modelu postavljen takav uvjet sustav nije proizveo niti jedan proizvod (tablica 5)

Tablica 5. Validacija Conwip modela – prvi granični uvjet

	Produktivnost – idealno [kom]	Produktivnost – broj CONWIP kartica, C=0 [kom]
CONWIP model	1950	0

Drugi granični uvjet bio je tempo pristizanja narudžbi u sustav, gdje je uzeto da vrijeme između dvije uzastopne narudžbe bude polovica ukupnog vremena trajanja simulacije. Dakle, ukupno vrijeme trajanja simulacije iznosi 117 000 minuta, te za ovo testiranje valjanosti Conwip modela uzeto da je vrijeme između dvije uzastopne narudžbe 58 000 minuta. Rezultati su odgovarali očekivanim vrijednostima. Sustav je proizveo 2 proizvoda (tablica 6)

Tablica 6. Validacija Kanban modela – drugi granični uvjet

	Produktivnost – idealno [kom]	Produktivnost – tempo potražnje 55 000 [kom]
CONWIP model	1950	2

Temeljem rezultata dobivenih postavljanjem graničnih uvjeta prilikom izvoženja simulacije, može se zaključiti da je Conwip mehanizam upravljanja dobro modeliran u simulacijskom modelu.

4.2.3 Validacija Hibrid modela

Kako i sam naziv ukazuje, hibridni Conwip/Kanban mehanizam je kombinacija Conwip i Kanban mehanizma upravljana proizvodnim procesom. U sustavu postoje i Conwip i Kanban kartice. Conwip kartice reguliraju ukupan broj materijala u procesu obrade te informaciju o potražnji prenose uvijek na sam početak proizvodnog procesa, dok Kanban kartice informaciju o potražnji šalju prema svakom radnom mjestu počevši od zadnjeg radnog mjesta u procesu, pa u suprotnom smjeru, od samog smjera kretanja proizvodnog procesa, proslijeđuju informaciju dalje. Na taj način, Kanban kartice direktno reguliraju količinu rada u procesu na pojedinom radnom mjestu dok Conwip kartice to čine za cijeli proces.

Ovakva karakteristika uloge pojedinih kartica u prijenosu informacija u procesu korištena je i pri validaciji Hibridnog Conwip/Kanban modela.

Prvi granični uvjet bio je:

- broj Conwip kartica jednak je nula
- broj Kanban kartica ostaje nepromijenjen

Kako je i očekivano proizvodni sustav nije proizveo niti jedan proizvod (tablica 7). Razlog je jasan. Conwip kartice ograničavaju količinu materijala u sustavu a kako je postavljeno da je taj broj jednak nuli proizvodnja je onemogućena, unatoč tome što su Kanban kartice mogle obaviti funkciju prijenosa informacije o potražnji.

Tablica 7. Validacija hibridnog Conwip/Kanban modela – prvi granični uvjet

	Produktivnost – idealno [kom]	Produktivnost – broj CONWIP kartica, C=0 [kom]
Hibridno CONWIP/Kanban model	1950	0

Drugi granični uvjet bio je:

- na radnom mjestu broj četiri nema Kanban kartica
- broj Conwip kartica ostaje ne promijenjen

U ovom slučaju sustav do određene mjere dobije informaciju o potražnji. Putem Conwip kartice materijal iz skladišta ulazi u proizvodnji proces u trenutku kada je pristigla narudžba. Također Kanban karticama ta ista informacija kreće od zadnjeg stroja uzvodno. No, na radnom mjestu 4 taj tijek informacija se prekida, te se proizvodni proces zaustavlja. Očekivano, proizvodni sustav nije proizveo niti jedan proizvod (tablica 8).

Tablica 8. Validacija hibridnog Conwip/Kanban modela – drugi granični uvjet

	Produktivnost – idealno [kom]	Produktivnost – nema Kanban kartice na zadnjem stroju, K4=0 [kom]
Kanban model	1950	0

4.2.4 Validacija DBR modela

Validacija DBR modela je provedena na isti način kao i kod CONWIP modela. Prvi granični uvjet kojim je provjerena valjanost DBR modela bio je broj DBR kartica. DBR kartice šalju informaciju o završetku obrade na uskom grlu. U trenutku kada obradak napusti usko grlo DBR kartica se šalje na početak proizvodnog procesa i to je signal za pokretanje proizvodnje na prvom radnom mjestu. Ukoliko se u simulacijskom modelu postavi da je

njihov broj jednak nuli, sustav ne bi trebao proizvesti niti jedan proizvod jer naprosto nema prijenosa informacije o tome da je obradak napustio usko grlo.. Kako je i očekivano, nakon što je u modelu postavljen takav uvjet sustav nije proizveo niti jedan proizvod (tablica 9)

Tablica 9 Validacija *DBR* modela – granični uvjet

	Produktivnost – idealno [kom]	Produktivnost – broj <i>DBR</i> kartica, <i>DBR</i> =0 [kom]
<i>DBR</i> model	1950	0

Temeljem rezultata postavljanjem graničnih uvjeta prilikom izvođenja simulacije, može se zaključiti da je *DBR* mehanizam upravljanja dobro modeliran.

4.3 Definiranje utjecajnih parametara i mjera performansi proizvodnog procesa

Cilj ovog istraživanja je analizirati kako promjena pojedinih parametara u proizvodnom procesu utječu na performanse procesa. Zasebno će biti analizirani procesi upravljani određenim mehanizmom upravljanja opisani u poglavlju 3.1.

Odluka o parametrima čiji će utjecaj na performanse proizvodnog procesa biti analiziran, donošena je pregledom literature ali i iskustvom provedenim u praksi prilikom implementiranja principa Vitke proizvodnje, posebno principa povlačenja materijala što je i područje ovog istraživanja.

U literaturi se jasno definira koji su to preduvjeti da bi princip povlačenja bilo moguće implementirati u proizvodnom procesu. Monden je definirao koji su to preduvjeti za uspješnu implementaciju Kanban mehanizma [4]:

1. Potražnja je približno konstantna u određenom planskom periodu
2. Mala vremena namještanja stroja
3. Balansiran proizvodni proces
4. Tečna proizvodnja – proizvodnja bez prevelikih zastoja

Iskustvo u praksi pokazalo je da neke od pojedinih preduvjeta vrlo često nije moguće u potpunosti postići. Potražnja je često nepredvidiva. Unatoč opsežnoj analizi i spremnosti poduzeća da u potpunosti reorganizira raspored strojeva u cilju postizanja izbalansiranih radnih stanica, ponekad u praksi nije bilo moguće postići potpunu izbalansiranost trajanja operacija na pojedinim radnim stanicama tj grupama operacija. Jedna bi faza zbog prirode procesa ostala usko grlo i pitanje je bilo ima li smisla u takvom procesu implementirati Kanban sustav ili bi neki drugi mehanizam upravljanja bio bolji odabir. Također, tečnu, bez zastoja i poremećaja proizvodnju u praksi je vrlo često teško dostići. Vrijeme trajanja operacija na pojedinim strojevima ili pojedinim radnim stanicama može varirati bilo zbog nepredviđenih zastoja, bilo zbog nastanka greške i dorade. U jednom proizvodnom poduzeću, gdje se provodio opsežan projekt implementacije Vitke proizvodnje pokazalo se da su česte izmjene radnica na pojedinim strojevima dovodile do različitih rezultata zbog nedovoljne uvježbanosti radnica za izvođenje operacije, što je značajno utjecalo na vrijeme trajanja same operacije.

Temeljem svega gore navedenog odlučeno je da će biti istraženi slijedeći utjecajni parametri:

1. Varijabilnost vremena trajanja operacija
2. Postojanje uskog grla u procesu
3. Vrijeme trajanja operacije

Kako je već navedeno biti će zasebno analizirani procesi upravljani jednim od odabranih mehanizama upravljanja proizvodnjom, redom Kanban, Conwip, Hibrid Kanban/Conwip, te DBR. Kako svaki od navedenih mehanizama upravljanja ima svoje parametre, a radi se o broju kartica koje direktno utječu na količinu materijala u međuspremnicima tj. u konačnici utječu na količinu rada u procesu ali indirektno i na vodeće vrijeme, tako je odlučeno u analizu dodati još jedan parametar a to je broj upravljačkih kartica. Sasvim očigledno, kod Kanban mehanizma upravljanja radi se o broju Kanban kartica, kod Conwip mehanizma upravljanja radi se o broju Conwip kartica itd. Ovaj parametar često nije istražen u literaturi. Naime veći broj autora na početku eksperimenta i analize utvrdi određeni broj kartica koji definira optimalnim te ga drži fiksnim pri variranju drugih utjecajnih parametara. No međutim, fiksni broj kartica ne daje najbolju karakteristiku tog mehanizma za svaku kombinaciju različitih razina utjecajnih parametara. Naime, na primjer, kod niske varijabilnosti vremena trajanja operacija, određeni broj Kanban kartica će dati optimalne performanse proizvodnog procesa. No, za visoku razinu varijabilnosti vremena trajanja operacija taj broj kartica neće biti dovoljan tj proizvodni proces neće funkcionirati optimalno. U tom slučaju veći broj kartica bi doveo do boljih performansi procesa. Zato se broj kartica u ovom istraživanju uzima kao još jedan dodatni parametar.

Konačno, parametri čiji se utjecaj istražuje su:

1. Varijabilnost vremena trajanja operacija
2. Postojanje uskog grka u procesu
3. Vrijeme trajanja operacije
4. Broj kartica (Kanban kartica, Conwip kartica, DBR kartica)

Performanse proizvodnog procesa koje će biti istražene u ovom radu jesu ukupno vodeće vrijeme proizvodnog procesa (eng. *lead time* – LT), te produktivnost.

Vodeće vrijeme je ukupno vrijeme proteklo od trenutka kada materijal tj. sirovina uđe u proces proizvodnje do trenutka kada je gotov proizvod spreman za isporuku kupcu [2].

Produktivnost je mjera koja pokazuje koliko je moguće proizvesti jedinica proizvoda u određenom vremenskom periodu.

Zašto su odabrane ove dvije veličine? Budući da je fokus ovog istraživanja glavni princip Vitke proizvodnje, a to je princip povlačenja, onda su i performanse proizvodnog procesa odabrane sukladno kontekstu Vitke proizvodnje. Cilj svake implementacije Vitke proizvodnje u konačnici jeste skraćenje vodećeg vremena. Jedna od definicija Vitke proizvodnje to vrlo jasno objašnjava:

„Vitka proizvodnja je proizvodna filozofija koja kada je implementirana skraćuje vrijeme od narudžbe kupca do isporuke gotovog proizvoda, eliminirajući sve izvore gubitaka u proizvodnom procesu“ [2].

Produktivnost je, također, vrlo važna performansa proizvodnog procesa. Naime, u nekim proizvodnim procesima, zbog pojedinih karakteristika, kao što su na primjer visoka varijabilnost vremena trajanja operacija ili nestalna potražnja, veliko smanjenje rada u procesu, koji je jedan od glavnih ciljeva Vitke proizvodnje, može utjecati na to da se produktivnost, odnosno razina usluge smanji iz razloga što ne postoje sigurnosne zalihe u procesu (rada u procesu) koji bi ublažili navedene nedostatke procesa a čime bi produktivnost držali na višem nivou.

Razine ulaznih parametara su definirane nakon što je opsežno pregledana literatura, te temeljem dosadašnjeg iskustva u radu sa različitim proizvodnim poduzećima. Razine su prikazane u tablici 10.

Tablica 10.: Razine utjecajnih parametara

	Razina 1	Razina 2
Vrijem trajanja operacije, (min)	5	60
Koeficijent varijacije	0,25	0,86
Postojanje uskog grla	Ne	Da
Broj kartica, (kom/RM)	2	3

4.4 Eksperimentalni rad

Proizvodni procesi su analizirani simulacijskim eksperimentiranjem.

Cilj provođenja simulacijskog eksperimenta je odrediti kako varirani parametri utječu na definirane mjerne performanse. U tu svrhu, potrebno je dobiti matematički model koji opisuje prirodu veze utjecajnih parametara i mjerne performanse, a metoda koja je korištena je metoda odzivne površine (eng. *Response Surface Methodology, RSM*).

Za provođenje eksperimenata odabran je generalni faktorski plan pokusa. Ovaj plan pokusa je odabran iz razloga jer su pojedini varirani parametri (ulazne varijable) numeričke varijable a pojedini su kategorijske varijable. U takvom slučaju pogodno je, upravo, koristiti generalni faktorski plan pokusa. U programskom paketu, Design Expert [40] pomoću kojeg je provedena analiza rezultata taj plan pokusa se još naziva „*multilevel categoric*“.

Nakon izvođenja simulacijskih eksperimenata prema generiranom planu pokusa, provedena je analiza varijance (ANOVA) kako bi se utvrdila značajnost članova modela (utjecajnih parametara). Matematički model (odzivna funkcija) dobiven je regresijskom analizom.

Članovi modela A, B, C i D jesu redom:

- A – koeficijent varijacije
- B – vrijeme trajanja operacije
- C – postojanje uskog grla
- D – broj upravljačkih kartica

4.4.1 Analiza procesa – Kanban

4.4.1.1 Mjerna performansa – produktivnost

U ovom poglavlju će biti prikazani rezultati analize podataka za opisivanje utjecaja varijabilnosti vremena obrade, vremena trajanja obrade, uskog grla i broja upravljačkih kartica na produktivnost proizvodnog procesa u slučaju kada je kao mehanizam upravljanja proizvodnim procesom korišten Kanban. Rezultati dobiveni simulacijskim eksperimentiranjem (Prilog A - 1) su obrađeni u svrhu dobivanja matematičkog modela koji opisuje utjecaj variranih parametara na mjernu performansu „produktivnost“.

U tablici analize varijance, (tablica 11) može se vidjeti da je postavljeni model značajan. Na to upućuje F-vrijednost koja iznosi 312 571,42. P-vrijednost, koja također ukazuje na značajnost modela upućuje na to da se hipoteza H_0 odbacuje. Naime, P-vrijednost treba biti manja od 0,05 za odbacivanje hipoteze H_0 . Hipoteza H_0 za postavljeni plan pokusa glasi: varijabilnost vremena obrade, vrijeme trajanja obrade, usko grlo i broj upravljačkih kartica ne utječu na produktivnost proizvodnog procesa.

P-vrijednosti za članove modela pokazuju da su članovi modela A, B, C i D, te interakcije AB, AC, AD, BC, BD, CD, ABC, ABD i ACD značajni parametri modela.

Odstupanje od modela, kako se vidi u tablici nije značajno i njegova F-vrijednost iznosi 0,93. Odstupanje od modela je veličina koja mjeri varijaciju vrijednosti mjerene veličine kod ponavljanja istih stanja pokusa oko njihove srednje vrijednosti. Ako je ta veličina značajna to znači da model nedovoljno dobro opisuje pojavu.

Tablica 11. Analiza varijance matematičkog modela koji opisuje utjecaj variranih parametara na produktivnost kada se procesom upravlja Kanban mehanizmom upravljanja

Izvor varijacije	Suma kvadrata odstupanja	Broj stupnjeva slobode	Srednji kvadrat odstupanja	F-vrijednost	P-vrijednost	Značajnost
Model	1896,68	13	145,90	$3,12 \times 10^5$	< 0,0001	značajan
Članovi modela						
A	3,08	1	3,08	6 594,23	< 0,0001	značajan
B	1 803,70	1	1 803,70	386 000	< 0,0001	značajan
C	49,09	1	49,09	105×10^5	< 0,0001	značajan

D	0,0050	1	0,0050	10,72	0,0017	značajan
AB	0,1545	1	0,1545	330,91	< 0,0001	značajan
AC	0,0564	1	0,0564	120,90	< 0,0001	značajan
AD	0,0052	1	0,0052	11,05	0,0014	značajan
BC	40,52	1	40,52	86813,54	< 0,0001	značajan
BD	0,0056	1	0,0056	11,94	0,0010	značajan
CD	0,0147	1	0,0147	31,54	< 0,0001	značajan
ABC	0,0246	1	0,0246	52,70	< 0,0001	značajan
ABD	0,0050	1	0,0050	10,82	0,0016	značajan
ACD	0,0198	1	0,0198	42,38	< 0,0001	značajan
Ostatak	0,0308	66	0,0005			
Odstupanje od modela	0,0009	2	0,0004	0,9300	0,399	nije značajno
Čista greška	0,0299	64	0,0005			
Ukupno	1896,72	79				

Vrijednost predviđenog koeficijenta determinacije, R_{pre}^2 ovog modela a koja iznosi 1 i vrijednost prilagođenog koeficijenta determinacije, R_{adj}^2 koji također iznosi 1, su u dobrom odnosu. To znači da je dobiveni regresijski model (odzivna funkcija) različit od slučajnih pojava (tablica 12). Na to ukazuje nužan uvjet a to je da je razlika između prilagođenog i predviđenog koeficijenta determinacije manja od 0,2 [40].

Aдекватna preciznost pokazuje omjer signal-šum, a njena vrijednost mora biti veća od 4. U tablici 12 se vidi da je za ovaj model ta vrijednost 1 264,623 što upućuje da se model može koristiti u eksperimentalnom prostoru [40].

Tablica 12. Veličine koje opisuju kvalitetu dobivenog matematičkog modela za izračun produktivnosti kod upravljanja procesom Kanban mehanizmom upravljanja

Standardna devijacija, mm	0,0216
Aritmetička sredina, mm	5,44
Koeficijent varijacije, %	0,3970

R^2 - koeficijent determinacije	0,999
R_{adj}^2 - prilagođeni koeficijent determinacije	0,999
R_{pre}^2 - predviđeni koeficijent determinacije	0,999
Aдекватna preciznost	1 264,6231

Temeljem rezultata dobivenih simulacijskim eksperimentiranjem procijenjeni su koeficijenti matematičkog (regresijskog) modela. Prvo je postavljen matematički model za izračun produktivnosti ovisno o utjecajnim parametrima u kodiranim vrijednostima:

$$\begin{aligned}
 P_{Kanban} = & 5,44 - 0,1950A - 4,74B - 0,7878C + 0,00159D + 0,0485AB \\
 & + 0,0191AC + 0,0082AD + 0,7152BC - 0,0087CD \\
 & + 0,0192ABC - 0,0075ACD
 \end{aligned}
 \tag{4-1}$$

gdje je:

P_{Kanban} - produktivnost, kom/h

A – koeficijent varijacije

B – vrijeme obrade, min

C – usko grlo

D - broj Kanban kartica na pojedinom radnom mjestu, kom/RM

Procijenjeni koeficijent uz član modela A (koeficijent varijacije) iznosi – 0,1962. Koeficijent je negativan, što znači da porastom veličine A, dakle, porastom koeficijenta varijacije vremena trajanja operacije razina produktivnosti pada. To odgovara stranoj pojavi. Koeficijent varijacije vremena trajanja operacije predstavlja varijabilnost tj odstupanje od vremena trajanja operacija uzrokovano bilo zastoјima, bilo pojavom grešaka i dorade , bilo nedovoljno dobre uvježbanosti radnika na stroju. Koeficijent uz član modela B (vrijeme obrade) iznosi -4,75. Koeficijent je također negativan što znači da porastom vremena trajanja operacije razina produktivnosti (broj proizvedenih komada na sat) opada. Procijenjeni koeficijent člana model C (usko grlo) iznosi -0,7834. Promjenom stanja procesa iz

nepostojanja uskog grla (početno stanje) u postojanje uskog grla u procesu vrijednost produktivnosti opada što također odgovara stvarnoj pojavi.

Matematički model s kodiranim vrijednostima članova modela iz izraza (4-1) prevodi se u model sa stvarnim vrijednostima članova modela prema [40]. Obzirom da je jedna od veličina, u ovom slučaju to je usko grlo, kategorijska varijabla, dobivena su dva matematička modela sa stvarnim vrijednostima članova modela. Prvi matematički model je za jednu razinu kategorijske varijable, u ovom slučaju to je razina „DA“, dakle postojanje uskog grla u procesu:

$$P_{Kanban-DA} = 9,85712 - 0,844392Cv - 0,150878t + 0,003959Br + 0,008078Cvt + 0,001504CvBr \quad (4-2)$$

Drugi matematički model je za drugu razinu kategorijske varijable, u ovom slučaju to je razina „NE“, dakle ne postojanje uskog grla u procesu:

$$P_{Kanban-NE} = 13,13354 - 0,936188Cv - 0,200347t - 0,002739Br + 0,003491Cvt + 0,034448CvBr \quad (4-3)$$

gdje je:

P_{Kanban} – produktivnost, kom/h


Cv - koeficijent varijacije

t - vrijeme trajanja operacije, min

Br - broj Kanban kartica na pojedinom radnom mjestu, kom/RM

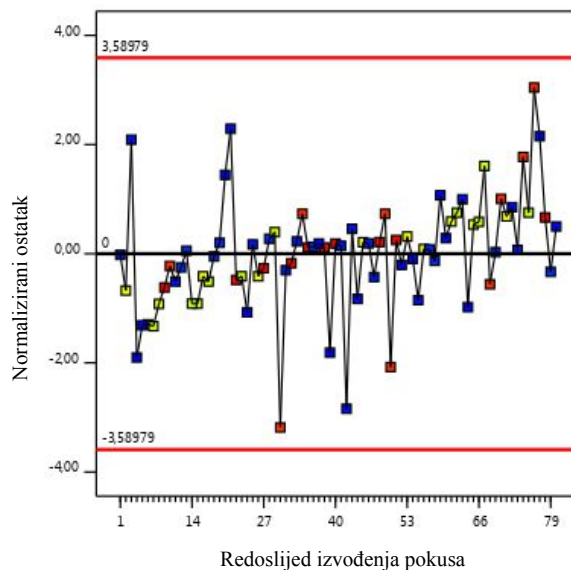
Normalizirani papir vjerojatnosti ostataka ispituje normalnost izmjerenih vrijednosti za pojedina stanja pokusa. Analiza varijance pretpostavlja kako su podaci svakog uzorka distribuirani normalno i nezavisno s istim varijancama za svaku razinu faktora. Slika 11 prikazuje normalizirani papir vjerojatnosti ostataka za pojedino stanje pokusa. Analiza

ostataka provodi se pregledom odstupanja ostataka od linije normalne razdiobe. Točke koje predstavljaju ostatke trebaju pratiti liniju normalne razdiobe. Ukoliko to nije slučaj, model treba korigirati. U ovom slučaju vidljivo je da su podaci raspoređeni po normalnoj razdiobi.




Slika 11: Normalizirani papir ostataka za matematički model za izračun produktivnosti kod upravljanja procesom Kanban mehanizmom upravljanja

Dijagram ostataka u odnosu na redoslijed izvođenja plana pokusa provjerava postojanje sustavne pogreške koja je mogla utjecati na odziv tijekom provođenja eksperimenta. Slika 12 prikazuje slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana pokusa. Na slici je vidljivo da ne postoji sustavna pogreška u pozadini, odnosno da se svi podaci nalaze unutar postavljenih granica vjerojatnosti ($\pm 3,59$).




Slika 12: Slučajno rasipanje ostataka u odnosu na redosljed izvođenja plana za matematički model za izračun produktivnosti kod upravljanja procesom Kanban mehanizmom upravljanja

Na slici 13 prikazan je konturni dijagram matematičkog modela za izračun produktivnosti u ovisnosti o visini koeficijenta varijacije i u ovisnosti o vremenu trajanja operacije. Veličine “usko grlo” i “broj Kanban kartica” su u ovom slučaju konstantne. Usko grlo postoji u procesu i to odgovara ulaznoj razini „DA“ za ovaj parametar. Broj Kanban kartica iznosi 5.




Slika 13. Konturni prikaz matematičkog modela za izračun produktivnosti ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju postojanja uskog grla u procesu i za slučaj 5 Kanban kartica po radnom mjestu

Slike 14 i 15 prikazuju 3D prikaze odzivnih površina matematičkog modela za produktivnost. Jednako kao i u konturnom prikazu na slici 15, za ovaj slučaj veličine “usko grlo” i “broj Kanban kartica” su konstantne, a mijenjaju se razine veličina “koeficijent varijacije” i “vrijeme trajanja obrade”. Naravno, produktivnost je moguće izračunati mijenjanjem svih ulaznih veličina, no za 3D prikaz dvije veličine je trebalo držati konstantnim. Može se vidjeti kako produktivnost pada sa povećanjem varijacija u procesu. Također, kada je vrijeme trajanje operacije duže broj proizvedenih jedinica proizvoda u jednom satu pada. Slika 14 pokazuje odzivnu površinu kada postoji usko grlo u procesu a slika 15 kada uskog grla nema. Odzivna površina pokazuje kako je produktivnost veća u slučaju kada u procesu nema uskog grla.



Slika 14. 3D prikaz matematičkog modela za izračun produktivnosti ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju postojanja uskog grla u procesu i za slučaj 5 Kanban kartica po radnom mjestu



Slika 15: 3D prikaz matematičkog modela za izračun produktivnosti ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju nepostojanja uskog grla u procesu i za slučaj 5 Kanban kartica po radnom mjestu

4.4.1.2 Mjerna performansa – vodeće vrijeme

U ovom poglavlju biti će prikazani rezultati analize podataka za opisivanje utjecaja varijabilnosti vremena obrade, vremena trajanja obrade, uskog grla i broja upravljačkih kartica na vodeće vrijeme proizvodnog procesa u slučaju upravljanja Kanban mehanizmom upravljanja. Svrha obrade rezultata dobivenih simulacijskim eksperimentiranjem (Prilog A - 1) ista je kao i za produktivnost a to je dobivanje matematičkog modela koji opisuje utjecaj variranih parametara proizvodnog procesa na performansu „vodeće vrijeme“.

Prije analize varijance, u ovom slučaju, bilo je potrebno napraviti transformaciju podataka. Naime, na ovom skupu podataka omjer maksimalne i minimalne mjerene vrijednosti je veći od 10, pa je u tom slučaju potrebna transformacija [40]. Na taj način je zadovoljena homogenost varijance po eksperimentalnom prostoru [42]. Podaci su transformirani prema izrazu (4-10):

$$y' = \ln(y+k), \quad k = 0 \quad (4-4)$$

gdje je:

y' – transformirani podatak

y - stvarni podatak

Prema tablici broj 15 koja prikazuje analizu varijance vidi se da je postavljeni model značajan na što upućuje F-vrijednost modela koja iznosi 1 169,75. P-vrijednost modela također ukazuje na značajnost modela. P-vrijednost upućuje na to da se hipoteza H_0 odbacuje. Naime, P-vrijednost treba biti manja od 0,05 za odbacivanje hipoteze H_0 . Hipoteza H_0 za postavljeni plan pokusa glasi: varijabilnost vremena obrade, vrijeme trajanja obrade, usko grlo i broj upravljačkih kartica ne utječu na vodeće vrijeme proizvodnog procesa.

U tablici 13 se također može vidjeti da su članovi modela A, B, C i D, te interakcije AB, AC, AD, BC, BD, CD, ABD i ACD značajni parametri modela jer su njihove P-vrijednosti manje od 0,05.

Odstupanje od modela, kako se vidi u tablici nije značajno i njegova F-vrijednost iznosi 0,3685. To znači da model dovoljno dobro opisuje pojavu [40].

Tablica 13. Analiza varijance matematičkog modela koji opisuje utjecaj variranih parametara na vodeće kada se procesom upravlja Kanban mehanizmom upravljanja

Izvor varijacije	Suma kvadrata odstupanja	Broj stupnjeva slobode	Srednji kvadrat odstupanja	F-vrijednost	P-vrijednost	Značajnost
Model	165,31	11	15,03	1 169,75	< 0,0001	značajan
Članovi modela						
A	2,48	1	2,48	193,02	< 0,0001	značajan
B	148,80	1	148,80	11581,87	< 0,0001	značajan
C	8,58	1	8,58	667,45	< 0,0001	značajan
D	3,39	1	3,39	264,03	< 0,0001	značajan
AB	0,0526	1	0,0526	4,10	0,0469	značajan
AC	0,6140	1	0,6140	47,79	< 0,0001	značajan
AD	0,1743	1	0,1743	13,57	0,0005	značajan
BC	0,2573	1	0,2573	20,03	< 0,0001	značajan
CD	0,6793	1	0,6793	52,87	< 0,0001	značajan
ABC	0,1425	1	0,1425	11,09	0,0014	značajan
ACD	0,1465	1	0,1465	11,41	0,0012	značajan
Ostatak	0,8736	68	0,0128			
Odstupanje od modela	0,0197	4	0,0049	0,3685	0,830	nije značajno
Čista greška	0,8540	64	0,0133			
Ukupno	166,19	79				

Vrijednost predviđenog koeficijenta determinacije, R_{pre}^2 ovog modela a koja iznosi 0,9927 i vrijednost prilagođenog koeficijenta determinacije, R_{adj}^2 , čija je vrijednost 0,9939 su u dobrom odnosu. Na to ukazuje nužan uvjet a to je da je razlika između prilagođenog i predviđenog koeficijenta determinacije manja od 0,2 [40] . Što znači da je dobiveni regresijski model (odzivna funkcija) različit od slučajnih pojava (tablica 14).

Vrijednost adekvatne preciznosti bi trebala biti veća od 4, a u tablici 14 se vidi da je za ovaj model ta vrijednost 94,4254 što upućuje na to da se model može koristiti u eksperimentalnom prostoru [40].

Tablica 14. Veličine koje opisuju kvalitetu dobivenog matematičkog modela za izračun vodećeg vremena kod upravljanja procesom Kanban mehanizmom upravljanja

Standardna devijacija, mm	0,1133
Aritmetička sredina, mm	5,58
Koeficijent varijacije, %	2,03
R^2 - koeficijent determinacije	0,9947
R_{adj}^2 - prilagođeni koeficijent determinacije	0,9939
R_{pre}^2 - predviđeni koeficijent determinacije	0,9927
Adekvatna preciznost	94,4254

Kako je za transformaciju podataka korišten prirodni logaritam, tako i dobiveni matematički model predstavlja matematičku funkciju za izračun vodećeg vremena u logaritamskom obliku. Takvu izračunatu vrijednost treba iz prirodnog algoritma transformirati u realan broj kao bi se dobila stvarna vrijednost varijable vodeće vrijeme. Matematički model u kodiranim vrijednostima glasi:

$$\begin{aligned} \ln(LT_{Kanban}) = & 5,58 + 0,1761A + 1,36B + 0,3274C + 0,2059D + \\ & 0,0256AB - 0,0876AC + 0,0467AD - 0,0567BC + 0,0921CD \\ & + 0,0422ABC - 0,0428ACD \end{aligned} \quad (4-5)$$

gdje je:

$\ln(LT_{Kanban})$ – prirodni logaritam veličine vodeće vrijeme, min

A – koeficijent varijacije

B – vrijeme obrade, min

C – usko grlo

D - broj Kanban kartica na pojedinom radnom mjestu, kom/RM

Vrijednost dobivena putem izraza (4-4) predstavlja prirodni logaritam veličine vodeće vrijeme. Kako bi dobili stvarni iznos veličine vodeće vrijeme, navedenu vrijednost treba transformirati u realan broj pomoću izraza (4-5).

$$LT_{Kanban} = e^{\ln(LT_{Kanban})} \quad (4-6)$$

Matematički model s kodiranim vrijednostima članova modela iz izraza (4-4) preveden u model sa stvarnim vrijednostima članova modela [40]. U slučaju nepostojanja uskog grla u procesu matematički model glasi:

$$\ln(LT_{Kanban-NE}) = 3,66826 - 0,002615Cv + 0,043041t + 0,194001Br + \\ 0,00809Cvt + 0,008481CvBr \quad (4-7)$$

Vrijednost dobivena putem izraza (4-6) predstavlja prirodni logaritam veličine vodeće vrijeme. Kako bi dobili stvarni iznos veličine vodeće vrijeme, navedenu vrijednost treba transformirati u realan broj pomoću izraza (4-7).

$$LT_{Kanban-NE} = e^{\ln(LT_{Kanban-NE})} \quad (4-8)$$

Matematički model s kodiranim vrijednostima članova modela iz izraza (4-7) preveden u model sa stvarnim vrijednostima članova modela u slučaju nepostojanja uskog grla u procesu glasi:

$$\ln(LT_{Kanban-DA}) = 3,17249 + 0,244123Cv + 0,052751t - 0,0327Br - 0,001974Cvt \\ + 0,195583CvBr \quad (4-9)$$

gdje je:

LT_{kanban} – vodeće vrijeme kada se za upravljanje proizvodnim procesom koristi Kanban, min

C_v - koeficijent varijacije


T - vrijeme trajanja operacije

Br - broj Kanban kartica na pojedinom radnom mjestu

Vrijednost dobivena putem izraza (4-9) predstavlja prirodni logaritam veličine vodeće vrijeme. Kako bi dobili stvarni iznos veličine vodeće vrijeme, navedenu vrijednost treba transformirati u realan broj pomoću izraza (4-10).


$$LT_{Kanban-NE} = e^{\ln(LT_{Kanban-NE})} \quad (4-10)$$

Slika 16 prikazuje normalizirani papir vjerojatnosti ostataka za pojedino stanje pokusa. Vidi se kako ostaci dobro prate liniju normalne razdiobe, što znači da je model uredi i nisu potrebne nikakve korekcije.




Slika 16. Normalizirani papir ostataka za matematički model za izračun vodećeg vremena kod upravljanja procesom Kanban mehanizmom upravljanja

Slika 17 prikazuje slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana pokusa. Na slici je vidljivo da ne postoji sustavna pogreška u pozadini, odnosno da se svi podaci nalaze unutar postavljenih granica vjerojatnosti ($\pm 3,59$).




Slika 17. Slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana za matematički model za izračun vodećeg vremena kod upravljanja procesom Kanban mehanizmom upravljanja

Na slikama 18 i 19 prikazani su konturni dijagrami matematičkog modela za izračun vodećeg vremena u ovisnosti o visini koeficijenta varijacije i u ovisnosti o vremenu trajanja operacije.




Slika 18. Konturni prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja operacije za slučaj nepostojanja uskog grla u procesu i za slučaj 2 Kanban kartice po radnom mjestu

Slika 18 prikazuje slučaj kad u procesu ne postoji usko grlo i kad u sustavu postoji 2 Kanban kartice po radnom mjestu. Slika 19 prikazuje konturni dijagram za iste postavke osim što je broj Kanban kartica po radnom mjestu u sustavu jednak 5. Može se vidjeti da u slučaju manjeg broja kartica vodeće vrijeme za istu razinu ostalih parametara je kraće.




Slika 19. Konturni prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja operacije za slučaj nepostojanja uskog grla u procesu i za slučaj 5 Kanban kartica po radnom mjestu

Slike 20 i 21, također prikazuju konturne dijagrame matematičkog modela za izračun vodećeg vremena, ali za slučaj postojanja uskog grla u procesu. Očekivano, za iste razine parametara vodeće vrijeme je duže nego u slučaju ne postojanja uskog grla. Također, jasno se vidi razlika u duljini trajanja vodećeg vremena ukoliko je u sustavu samo 2 kartice po radnom ili ako je u sustavu 5 Kanban kartica po radnom mjestu.




Slika 20. Konturni prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja operacije za slučaj postojanja uskog grla u procesu i za slučaj 2 Kanban kartice po radnom mjestu




Slika 21. Konturni prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja operacije za slučaj postojanja uskog grla u procesu i za slučaj 5 Kanban kartica po radnom mjestu

Kako varijacije u proizvodnom procesu utječu na duljinu vodećeg vremena jasno prikazuje odzivne površine matematičkog modela prikazane na slikama 22 i 23. Obje slike prikazuju slučaj kada u procesu postoji usko grlo s jedinom razlikom a to je broj Kanban kartica.



Slika 22. 3D prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja operacije za slučaj postojanja uskog grla u procesu i za slučaj 2 Kanban kartice po radnom mjestu

Na slici 22 je slučaj proizvodnog procesa sa uskim grlom kada je u procesu manji broj Kanban kartica. U slučaju kada se u procesu koriste dvije Kanban kartice po radnom mjestu vodeće vrijeme je kraće. Tako, kada operacije traju 60 minuta a koeficijent varijacije iznosi 0,25 vodeće vrijeme je 750 minuta (slika22). Za isto vrijeme trajanja operacije ali za slučaj kada koeficijent varijacije za vrijeme trajanja operacije iznosi 0,86, vodeće vrijeme je znatno duže i iznosi 1 200 minuta (slika22). Porastom koeficijenta varijabilnosti vremena trajanja obrade raste i duljina trajanja vodećeg vremena. Kako u ovom modelu koeficijent varijabilnosti modelira sve varijacije u procesu nastale uslijed nepredviđenih situacija kao što su zastoji, greške ili dorade jasno je da sve ono što uzrokuje varijabilnost vremena trajanja obrade treba svesti na najmanju moguću mjeru.



Slika 23. 3D prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja operacije za slučaj postojanja uskog grla u procesu i za slučaj 5 Kanban kartica po radnom mjestu

Na slici 23 je prikazan odzivna površina matematičkog modela za slučaj proizvodnog procesa sa uskim grlom kada je u procesu veći broj Kanban kartica. Vidljivo je kako u slučaju većeg broja upravljačkih kartica u procesu vodeće vrijeme traje znatno duže. Također, vidljivo je kako se porastom koeficijenta varijacije u ovom slučaju vrijednost vodećeg vremena značajnije povećava nego kad je u sustavu manje upravljačkih kartica. Iz tog razloga cilj je u proizvodnom procesu sve uzroke varijacija vremena trajanja operacija svesti na najmanju moguću mjeru te osigurati preduvjete za primjenu što manjeg broja upravljačkih kartica.

4.4.2 *Analiza procesa – CONWIP*

4.4.2.1 Mjerna performansa – produktivnost

Rezultati dobiveni simulacijskim eksperimentiranjem (Prilog A - 2) u svrhu dobivanja matematičkog modela koji opisuje utjecaj variranih parametara proizvodnog procesa na performansu „produktivnost“ za slučaj kada je kao mehanizam upravljanja proizvodnim procesom korišten Conwip biti će prikazani u ovom poglavlju.

Prije analize varijance, u ovom slučaju, bilo je potrebno napraviti transformaciju podataka. Naime, na ovom skupu podataka omjer maksimalne i minimalne mjerene vrijednosti je veći od 10, pa je u tom slučaju potrebna transformacija [40]. Na taj način je zadovoljena homogenost varijance po eksperimentalnom prostoru [42]. Podaci su transformirani prema izrazu (4-11):

$$y' = (y+k)^{\lambda}, \quad k = 0, \quad \lambda = 0,88 \quad (4-11)$$

gdje je:

y' – transformirani podatak

y - stvarni podatak

Kako se vidi u tablici analize varijance, postavljeni model je značajan. Na to upućuju F-vrijednost čija vrijednost iznosi 275 659,74. te također P-vrijednost, čija je vrijednost manja od 0,05 što je uvjet za odbacivanje hipoteze H_0 . Hipoteza H_0 za postavljeni plan pokusa glasi: varijabilnost vremena obrade, vrijeme trajanja operacije, usko grlo te broj Conwip kartica ne utječu na produktivnost proizvodnog procesa.

Dobiveni model dovoljno dobro opisuje pojavu, na što upućuje F-vrijednost veličine „odstupanje od modela“ a koja iznosi 1,61.

Značajni članovi ovog matematičkog modela su: A, B, C i D, te interakcije AB, AC, AD, BC, CD, ABC i ACD, budući da je njihova P - vrijednost manja od 0,05. Član BD nije značajan, no zbog značajnih drugih interakcija, u svrhu podržavanja hijerarhije modela taj član se zadržava.

Tablica 15. Analiza varijance matematičkog modela koji opisuje utjecaj variranih parametara na produktivnost kada se procesom upravlja Conwip mehanizmom upravljanja

Izvor varijacije	Suma kvadrata odstupanja	Broj stupnjeva slobode	Srednji kvadrat odstupanja	F-vrijednost	P-vrijednost	Značajnost
Model	1012,62	12	84,38	$2,757 \times 10^5$	$< 0,0001$	značajan
Članovi modela						
A	1,72	1	1,72	5606,23	$< 0,0001$	značajan
B	972,16	1	972,16	$3,176 \times 10^6$	$< 0,0001$	značajan
C	21,87	1	21,87	71 453,50	$< 0,0001$	značajan
D	0,0095	1	0,0095	30,99	$< 0,0001$	značajan
AB	0,0241	1	0,0241	78,87	$< 0,0001$	značajan
AC	0,0578	1	0,0578	188,66	$< 0,0001$	značajan
AD	0,0100	1	0,0100	32,79	$< 0,0001$	značajan
BC	16,74	1	16,74	54 685,03	$< 0,0001$	značajan
BD	0,0021	1	0,0021	6,97	0,0972	nije značajan
CD	0,0069	1	0,0069	22,56	$< 0,0001$	značajan
ABC	0,0139	1	0,0139	45,34	$< 0,0001$	značajan
ACD	0,0036	1	0,0036	11,62	0,0006	značajan
Ostatak	0,0205	67	0,0005			
Odstupanje od modela	0,0014	3	0,0003	1,61	0,5633	nije značajan
Čista greška	0,0191	64	0,0005			
Ukupno	1012,64	79				

Dobiveni regresijski model (odzivna funkcija) različit je od slučajnih pojava. Na to ukazuje nužan uvjet a to je da je razlika između prilagođenog i predviđenog koeficijenta determinacije manja od 0,2 [40].

Aдекватna preciznost pokazuje omjer signal-šum, a njena vrijednost mora biti veća od 4. U tablici 16 se vidi da je za ovaj model ta vrijednost 1 176,591 što upućuje da se model može koristiti za analizu u eksperimentalnom prostoru [40].

Tablica 16. Veličine koje opisuju kvalitetu dobivenog matematičkog modela za izračun produktivnosti kod upravljanja procesom Conwip mehanizmom upravljanja

Standardna devijacija, mm	0,0175
Aritmetička sredina, mm	4,22
Koeficijent varijacije, %	0,4145
R^2 - koeficijent determinacije	0,999
R_{adj}^2 - prilagođeni koeficijent determinacije	0,999
R_{pre}^2 - predviđeni koeficijent determinacije	0,999
Aдекватna preciznost	1 176,591

Matematički model za izračun produktivnosti, dobiven regresijskom analizom u kodiranim vrijednostima glasi:

$$\begin{aligned}
 (P_{conwip})^{0,88} = & 4,22 - 0,1465B - 3,49B - 0,5229C + 0,0109D + 0,0174AB \\
 & + 0,0269AC + 0,0112AD + 0,4574BC + 0,0052BD - 0,0093CD \\
 & + 0,0132ABC - 0,0067ACD
 \end{aligned} \quad (4-12)$$

Vrijednosti dobivene putem izraza (4-12) potrebno je transformirati u stvarne vrijednosti pomoću izraza (4-12):

$$P_{conwip} = \sqrt[0,88]{(P_{conwip})^{0,88}} \quad (4-13)$$

Matematički model s kodiranim vrijednostima članova modela iz izraza (4-12) prevodi se u model sa stvarnim vrijednostima [40]. Model u slučaju nepostojanja uskog grla glasi:

$$\begin{aligned}
 (P_{conwip-NE})^{0,88} = & 9,82046 - 0,877525Cv - 0,144614t - 0,036874Br + 0,0051Cvt \\
 & + 0,117177CvBr + 0,000376tBr
 \end{aligned} \quad (4-14)$$

Vrijednosti dobivene putem izraza (4-14) potrebno je transformirati u stvarne vrijednosti pomoću izraza (4-12).

Matematički model sa stvarnim veličinama u slučaju postojanja uskog grla glasi:

$$(P_{conwip-DA})^{0,88} = 7,6239 - 0,584773Cv - 0,113088t - 0,025503Br + 0,003642Cvt + 0,029719CvBr + 0,000376tBr \quad (4-15)$$

gdje je:

P_{Conwip} – produktivnost, kom/h


Cv - koeficijent varijacije

t - vrijeme trajanja operacije, min

Br - broj Conwip kartica na pojedinom radnom mjestu, kom/RM


Vrijednosti dobivene putem izraza (4-15) potrebno je transformirati u stvarne vrijednosti pomoću izraza (4-13).

Slika 24 prikazuje normalizirani papir vjerojatnosti ostataka za pojedino stanje pokusa. Vidi se kako ostaci dobro prate liniju normalne razdiobe, što znači da je model uredi i nisu potrebne nikakve korekcije.




Slika 24. Normalizirani papir ostataka za matematički model za izračun produktivnosti kod upravljanja procesom Conwip mehanizmom upravljanja

Slika 25 prikazuje slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana pokusa. Na slici je vidljivo da ne postoji sustavna pogreška u pozadini, odnosno da se svi podaci nalaze unutar granica vjerojatnosti ($\pm 3,59$).




Slika 25. Slučajno rasipanje ostataka u odnosu na redosljed izvođenja plana za matematički model za izračun produktivnosti kod upravljanja procesom *Conwip* mehanizmom upravljanja

Slike 26 i 27 prikazuju odzivne površine matematičkog modela za izračun produktivnosti za slučaj postojanja uskog grla (slika 26) i u slučaju kada u procesu nema uskog grla (slika 27). Jasno se vidi razlika u postignutim razinama produktivnosti, te kako koeficijent varijacije i vrijeme trajanja operacije utječu na produktivnost.



Slika 26. 3D matematičkog modela za izračun produktivnosti ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju postojanja uskog grla u procesu i za slučaj 2 *Conwip* kartice po radnom mjestu (10 *Conwip* ukupno)



Slika 27. 3D matematičkog modela za izračun produktivnosti ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju nepostojanja uskog grla u procesu i za slučaj 2 Conwip kartice po radnom mjestu (10 Conwip u

4.4.2.2 Mjerna performansa – vodeće vrijeme

Rezultati dobiveni simulacijskim eksperimentiranjem (Prilog A - 2) u svrhu dobivanja matematičkog modela koji opisuje utjecaj variranih parametara proizvodnog procesa na performansu „vodeće vrijeme“ za slučaj kada je kao mehanizam upravljanja proizvodnim procesom korišten Conwip biti će prikazani u ovom poglavlju.

Prije analize varijance, i u ovom slučaju, bilo je potrebno napraviti transformaciju podataka, budući je u ovom skupu podataka omjer maksimalne i minimalne mjerene vrijednosti veći od 10, pa je u tom slučaju potrebna transformacija [40]. Na taj način je zadovoljena homogenost varijance po eksperimentalnom prostoru [42]. Podaci su transformirani prema izrazu (4-16):

$$y' = (y+k)^\lambda, \quad k = 0, \quad \lambda = 0,25 \quad (4-16)$$

gdje je:

y' – transformirani podatak

y - stvarni podatak

F – vrijednost, koja se može vidjeti u tablici analize varijance, pokazuje da je postavljeni model značajan. Njen iznos je 1 106,9. Postoji samo 0,01% vjerojatnosti da je F-vrijednost ovoliko iznosi zbog šuma [40]. Također, P-vrijednost, koja također ukazuje na značajnost modela upućuje na to da se hipoteza H_0 odbacuje. Hipoteza H_0 za postavljeni plan pokusa glasi: varijabilnost vremena obrade, vrijeme trajanja operacije, usko grlo te broj Conwip kartica ne utječu na vodeće vrijeme proizvodnog procesa.

Odstupanje od modela, kako se vidi u tablici nije značajno i njegova F-vrijednost iznosi 2,09. To znači da model dovoljno dobro opisuje pojavu [40].

Također, P-vrijednosti za članove modela upućuju da su članovi modela A, B, C i D, te interakcije AB, BC, BD, CD i BCD značajni parametri modela. Njihova p-vrijednost je manja od 0,05 čime je uvjet značajnosti zadovoljen.

Tablica 17. Analiza varijance matematičkog modela koji opisuje utjecaj variranih parametara na vodeće vrijeme kada se procesom upravlja *Conwip* mehanizmom upravljanja

Izvor varijacije	Suma kvadrata odstupanja	Broj stupnjeva slobode	Srednji kvadrat odstupanja	F-vrijednost	P-vrijednost	Značajnost
Model	143,46	12	11,95	1 106,90	< 0,0001	značajan
Članovi modela						
A	0,5033	1	0,5033	46,60	< 0.0001	značajan
B	133,04	1	133,04	12317,76	< 0.0001	značajan
C	6,81	1	6,81	630,09	< 0.0001	značajan
D	1,79	1	1,79	165,94	< 0.0001	značajan
AB	0,0058	1	0,0058	0,5400	0,4650	značajan
AC	0,0685	1	0,0685	6,34	0,0142	značajan
AD	0,0129	1	0,0129	1,19	0,2789	
BC	0,5327	1	0,5327	49,33	< 0.0001	značajan
BD	0,0201	1	0,0201	1,86	0,1774	
CD	0,6044	1	0,6044	55,96	< 0.0001	značajan
ABD	0,0441	1	0,0441	4,09	0,0472	
ACD	0,0330	1	0,0330	3,05	0,0851	
Ostatak	0,7236	67	0,0108			značajan
Odstupanje od modela	0,0644	3	0,0215	2,09	0,1109	nije značajno
Čista greška	0,6592	64	0,0103			
Ukupno	144,18	79				

Vrijednost predviđenog koeficijenta determinacije, R_{pre}^2 ovog modela a koja iznosi 0,995 i vrijednost prilagođenog koeficijenta determinacije, R_{adj}^2 u iznosu od 0,9941 su usklađene (tablica 18). To pokazuju da je dobiveni regresijski model (odzivna funkcija) različit od slučajnih pojava. Na to ukazuje nužan uvjet a to je da je razlika između prilagođenog i predviđenog koeficijenta determinacije manja od 0,2 [40].

Aдекватна preciznost pokazuje omjer signal-šum, a njena vrijednost mora biti veća od 4 [40]. U tablici 18 se vidi da je za ovaj model ta vrijednost 85,0434 što upućuje da se model može koristiti za analizu u eksperimentalnom prostoru

Tablica 18. Veličine koje opisuju kvalitetu dobivenog matematičkog modela za izračun vodećeg vremena kod upravljanja procesom *Conwip* mehanizmom upravljanja

Standardna devijacija, mm	0,1039
Aritmetička sredina, mm	4,05
Koeficijent varijacije, %	2,56
R^2 - koeficijent determinacije	0,9950
R_{adj}^2 - prilagođeni koeficijent determinacije	0,9941
R_{pre}^2 - predviđeni koeficijent determinacije	0,9928
Aдекватna preciznost	85,0434

Matematički model za izračun vodećeg vremena, dobiven regresijskom analizom u kodiranim vrijednostima glasi:

$$\begin{aligned}
 (LT_{Conwip})^{0,25} = & 4,05 + 0,0793A + 1,29B + 0,2917C + 0,1497D - \\
 & 0,0085AB - 0,0293AC - 0,0127AD + 0,0816BC + \\
 & 0,0158BD + 0,0869D - 0,0235ABD - 0,0203ACD
 \end{aligned} \quad (4-17)$$

Vrijednosti dobivene putem izraza (4-17) potrebno je transformirati u stvarne vrijednosti pomoću izraza (4-18):

$$LT_{conwip} = \sqrt[0,25]{(LT_{conwip})^{0,25}} \quad (4-18)$$

Matematički model sa stvarnim veličinama u slučaju nepostojanja uskog grla glasi [40]:

$$(LT_{Conwip-NE})^{0,25} = 2,22138 - 0,190956Cv + 0,033839t - 0,040703Br + 0,012985 Cvt + 0,232022CvBr + 0,004261tBr - 0,005601CvtBr \quad (4-19)$$

Vrijednosti dobivene putem izraza (4-19) potrebno je transformirati u stvarne vrijednosti pomoću izraza (4-18).

Matematički model sa stvarnim veličinama u slučaju postojanja uskog grla glasi [40]:

$$LT_{Conwip-DA} = 1,47958 + 0,282961Cv + 0,039774t + 0,454797Br + 0,012985Cvt - 0,034308CvBr + 0,004261tBr - 0,005601CvtBr \quad (4-20)$$

gdje je:

LT_{conwip} – vodeće vrijeme kada se za upravljanje proizvodnim procesom koristi Kanban, min


Cv - koeficijent varijacije

T - vrijeme trajanja operacije, min

Br - broj Kanban kartica na pojedinom radnom mjestu, kom/RM


Vrijednosti dobivene putem izraza (4-20) potrebno je transformirati u stvarne vrijednosti pomoću izraza (4-18).

Normalizirani papir vjerojatnosti ostataka ispituje normalnost izmjerenih vrijednosti za pojedina stanja pokusa. Analiza varijance pretpostavlja kako su podaci svakog uzorka distribuiran i normalno i nezavisno s istim varijancama t za svaku razinu faktora. Slika 28 prikazuje normalizirani papir vjerojatnosti ostataka za pojedino stanje pokusa. Analiza ostataka provodi se pregledom odstupanja ostataka od linije normalne razdiobe. Točke koje predstavljaju ostatke trebaju pratiti liniju normalne razdiobe. Ukoliko to nije slučaj, model treba korigirati. U ovom slučaju vidljivo je da su podaci raspoređeni po normalnoj razdiobi.




Slika 28. Normalizirani papir ostataka za matematički model za izračun vodećeg vremena kod upravljanja procesom *Conwip* mehanizmom upravljanja

Dijagram ostataka u odnosu na redosljed izvođenja plana pokusa provjerava postojanje sustavne pogreške koja je mogla utjecati na odziv tijekom provođenja eksperimenta. Slika 29 prikazuje slučajno rasipanje ostataka u odnosu na redosljed izvođenja plana pokusa na kojoj je vidljivo da ne postoji sustavna pogreška u pozadini, odnosno da se svi podaci nalaze unutar postavljenih granica vjerojatnosti ($\pm 3,58$).




Slika 29. Slučajno rasipanje ostataka u odnosu na redosljed izvođenja plana za matematički model za izračun vodećeg vremena kod upravljanja procesom *Conwip* mehanizmom upravljanja

Konturni dijagrami prikazan na slikama 30 i 31 zorno pokazuju kako se vodeće vrijeme u Conwip sustavu mijenja ovisno o tome koliki je ukupan broj Conwip kartica u sustavu.




Slika 30. Konturni prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade slučajnog postojanja uskog grla u procesu i za slučaj 3 kartice po radnom mjestu (15 *Conwip* kartica za cijeli proces)

Slika 30 pokazuje slučaj kada je u sustavu ukupno 15 *Conwip* kartica (3 kartice po stroju u prosjeku), a slika 31 prikazuje slučaj kada je u sustavu 10 *Conwip* kartica u sustavu (prosječno 2 *Conwip* kartice po stroju). Broj *Conwip* kartica u proizvodnom procesu utječe na način da, ukoliko je u procesu veći broj kartica, vodeće vrijeme se povećava. To je i očekivano, budući da veći broj kartica znači i veću količinu rada u procesu što u konačnici dovodi do dužeg vodećeg vremena. U slučaju kada imamo proces sa puno varijabilnosti, dakle proces koji nije stabilan onda većim brojem kartica tj. većim brojem rada u procesu se ta nestabilnost ublaži. Na primjer u slučaju nekog privremenog zastoja u ako imamo rad u procesu u izlaznom međuskladištu te faze na kojoj se dogodio zastoj, faza iza neće biti zaustavljena jer će moći raditi dalje na sigurnosnoj zalihi preuzetoj od prethodne faze, koja je u trenutnom zastoju. Manji broj kartica u sustavu tj. manja količina sigurnosnih zaliha, u ovom slučaju to bi dovela do neminovnog zastoja lančano u svim idućim fazama procesa što bi značajno narušilo produktivnost i razinu usluge.




Slika 31. Konturni prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade slučaju nepostojanja uskog grla u procesu i za slučaj 2 *Conwip* kartice po radnom mjestu (10 *Conwip* ukupno)

Odnos vrijednosti performanse vodeće vrijeme za slučaj većeg ili manjeg broja kartica u proizvodnom procesu prikazan je i na 3D prikazima matematičkog modela za izračun vodećeg vremena (slike 32 i 33). Na slikama se vidi i kako se vodeće vrijeme mijenja ovisno u varijacijama u procesu, odnosno kao je vodeće vrijeme duže u slučaju većeg koeficijenta varijacije.



Slika 32. 3D prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju postojanja uskog grla u procesu i za slučaj 3 *Conwip* kartice po radnom mjestu (15 *Conwip* kartica ukupno)



Slika 33. 3D prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju postojanja uskog grla u procesu i za slučaj 2 Conwip kartice po radnom mjestu (10 Conwip kartica za cijeli proces)

4.4.3 Analiza procesa – Hibrid Kanban/CONWIP

4.4.3.1 Mjerna performansa - produktivnost

U ovom poglavlju će biti prikazani rezultati dobiveni simulacijskim eksperimentiranjem (Prilog A - 3) u svrhu dobivanja matematičkog modela koji opisuje utjecaj variranih parametara proizvodnog procesa na performansu „produktivnost“ za slučaj kada je kao mehanizam upravljanja proizvodnim procesom korišten hibrid Kanban/Conwip mehanizam upravljanja.

Prije analize varijance bilo je potrebno napraviti transformaciju podataka, budući je u ovom skupu podataka omjer maksimalne i minimalne mjerene vrijednosti veći od 10 [40]. Na taj način je zadovoljena homogenost varijance po eksperimentalnom prostoru [42]. Podaci su transformirani prema izrazu (4-21):

$$y' = (y+k)^\lambda, \quad k = 0, \quad \lambda = 0,81 \quad (4-21)$$

gdje je:

y' – transformirani podatak

y - stvarni podatak

Dobiveni matematički model je značajan. Uvjet za to jesu F-vrijednost koja iznosi 294 858,32, te P-vrijednost koja treba biti manja od 0,05. P – vrijednost pokazuje da se hipoteza H_0 odbacuje. Hipoteza H_0 za postavljeni plan pokusa glasi: varijabilnost vremena obrade, vrijeme trajanja operacije, usko grlo, te broj Conwip kartica ne utječu na produktivnost proizvodnog procesa.

Značajni članovi ovog modela su A, B, C i D, te AB, AC, AD, BC, BD, CD, ABC, ABD i ACD jer su njihove P-vrijednosti manje od 0,05.

Odstupanje od modela, kako se vidi u tablici 19 nije značajno i njegova F-vrijednost iznosi 0,1726. Odstupanje od modela je veličina koja mjeri varijaciju vrijednosti mjerene veličine kod ponavljanja istih stanja pokusa oko njihove srednje vrijednosti. Ako je ta veličina značajna to znači da model nedovoljno dobro opisuje pojavu. Kako F-vrijednost veličine „odstupanje od modela“ nije značajan to znači da model dovoljno dobro opisuje pojavu.

Tablica 19. Analiza varijance matematičkog modela koji opisuje utjecaj variranih parametara na produktivnost kada se procesom upravlja hibridnim mehanizmom upravljanja

Izvor varijacije	Suma kvadrata odstupanja	Broj stupnjeva slobode	Srednji kvadrat odstupanja	F-vrijednost	P-vrijednost	Značajnost
Model	703,33	13	54,10	2,949 x 105	< 0,0001	značajan
Članovi modela						
A	675,94	1	675,94	3,684E+06	< 0,0001	značajan
B	13,66	1	13,66	74455,62	< 0,0001	značajan
C	0,0081	1	0,0081	44,01	< 0,0001	značajan
D	0,0146	1	0,0146	28,68	< 0,0001	značajan
AB	0,0053	1	0,0053	28,84	< 0,0001	značajan
AC	0,0484	1	0,0484	263,63	< 0,0001	značajan
AD	0,0044	1	0,0044	23,84	< 0,0001	značajan
BC	9,77	1	9,77	53259,45	< 0,0001	značajan
BD	0,0020	1	0,0020	10,68	0,0017	značajan
CD	0,0081	1	0,0081	44,10	< 0,0001	značajan
ABC	0,0099	1	0,0099	54,16	< 0,0001	značajan
ABD	0,0015	1	0,0015	8,22	0,0056	
ACD	0,0049	1	0,0049	26,76	<	
Ostatak	0,0121	66	0,0002			
Odstupanje	0,0006	2	0,0003	1,81	0,1726	nije značajno
Čista greška	0,0115	64	0,0002			
Ukupno	703,34	79				

Vrijednost predviđenog koeficijenta determinacije, R_{pre}^2 i prilagođenog koeficijenta determinacije, R_{adj}^2 pokazuju da je dobiveni regresijski model (odzivna funkcija) različit od slučajnih pojava (tablica 20). Na to ukazuje nužan uvjet a to je da je razlika između prilagođenog i predviđenog koeficijenta determinacije manja od 0,2 [40].

Adekvatna preciznost pokazuje omjer signal-šum, a njena vrijednost mora biti veća od 4. U tablici se vidi da je za ovaj model ta vrijednost 1 214,6028 što upućuje da se model može koristiti za analizu u eksperimentalnom prostoru.

Tablica 20. Veličine koje opisuju kvalitetu dobivenog matematičkog modela za izračun produktivnosti kod upravljanja procesom hibridnim mehanizmom upravljanja

Standardna devijacija, mm	0,0135
Aritmetička sredina, mm	3,66
Koeficijent varijacije, %	0,3702
R^2 - koeficijent determinacije	0,999
R_{adj}^2 - prilagođeni koeficijent determinacije	0,999
R_{pre}^2 - predviđeni koeficijent determinacije	0,999
Adekvatna preciznost	1 214,6028

Temeljem rezultata dobivenih simulacijskim eksperimentiranjem procijenjeni su koeficijenti matematičkog modela. Matematički model za izračun produktivnosti, dobiven regresijskom analizom u kodiranim vrijednostima glasi:

$$\begin{aligned}
 (P_{hibrid})^{0,81} = & 3,66 - 0,1195A - 2,91B - 0,414C + 0,0101D - 0,0081AB \\
 & + 0,0246AC + 0,0074AD + 0,3502BC + 0,005BD - 0,0101CD \quad (4-22) \\
 & + 0,0112ABC + 0,0044ABD - 0,0079ACD
 \end{aligned}$$

Kako su podaci transformirani pomoću izraza (4-21) potrebno ih je transformirati putem slijedećeg izraza:

$$y = \sqrt[\lambda]{y'}, \quad \lambda=0,81 \quad (4-23)$$

Za vrijednosti dobivene putem izraza (4-22) izraz za transformaciju glasi:

$$P_{hibrid} = \sqrt[0,81]{(P_{hibrid})^{0,81}} \quad (4-24)$$

Matematički model sa stvarnim veličinama u slučaju nepostojanja uskog grla glasi:

$$P_{hibrid-NE} = 8,16982 - 0,563684Cv - 0,116823t - 0,008266Br - 0,004897Cvt \\ + 0,066395CvBr - 0,000215tBr + 0,001038CvtBr \quad (4-25)$$

Vrijednosti dobivene putem izraza (4-25) potrebno je transformirati u stvarne vrijednosti pomoću izraza (4-24).

Matematički model sa stvarnim veličinama u slučaju nepostojanja uskog grla glasi

$$P_{hibrid-DA} = 6,43031 - 0,231142Cv - 0,092833t + 0,008571Br - 0,002235Cvt \\ - 0,036615CvBr - 0,000215tBr + 0,001038CvtBr \quad (4-26)$$

gdje je:

P_{hibrid} – produktivnost, kom/h


Cv - koeficijent varijacije

t - vrijeme trajanja operacije, min

Br - broj Kanban kartica na pojedinom radnom mjestu, kom/RM


Vrijednosti dobivene putem izraza (4-26) potrebno je transformirati u stvarne vrijednosti pomoću izraza (4-24).

Normalizirani papir vjerojatnosti u ovom slučaju pokazuje je da su podaci raspoređeni po normalnoj razdiobi (slika 34)



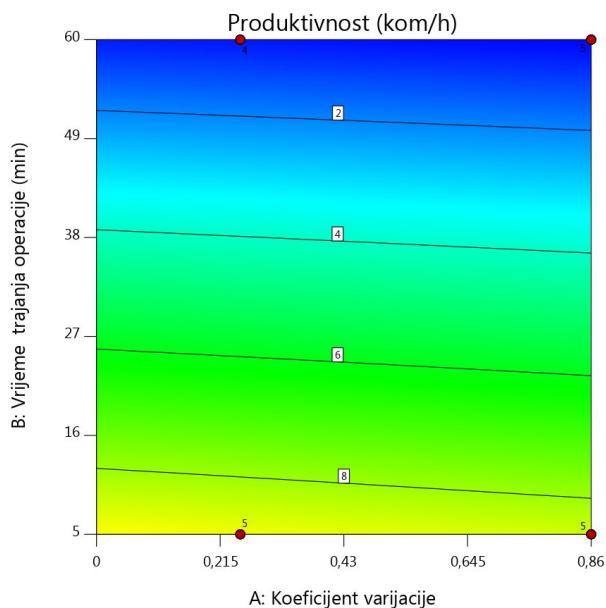
Slika 34. Normalizirani papir ostataka za matematički model za izračun produktivnosti kod upravljanja procesom hibridnim mehanizmom upravljanja

Slika 35 prikazuje slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana pokusa na kojoj je vidljivo da ne postoji sustavna pogreška u pozadini, odnosno da se svi podaci nalaze unutar postavljenih granica vjerojatnosti ($\pm 3,58$).




Slika 35. Slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana za matematički model za izračun produktivnosti kod upravljanja procesom hibridnim mehanizmom upravljanja

Na slici 36 prikazan je konturni dijagram matematičkog modela za izračun produktivnosti u ovisnosti o visini koeficijenta varijacije i u ovisnosti o vremenu trajanja operacije. U ovom slučaju radi se o procesu koji ima usko grlo a broj Conwip kartica ukupno iznosi 15 (3 kartice po stroju u prosjeku). Konturne linije koje pokazuju vrijednosti produktivnosti padaju sa povećanjem koeficijenta varijacije.




Slika 36. Konturni prikaz matematičkog modela za izračun produktivnosti ovisno o razini koeficijenta varijacije i vremena trajanja obrade slučaju postojanja uskog grla u procesu i za slučaj 3 Conwip kartice po radnom mjestu (15 kartica za cijeli proces)

Slike 37 i 38 prikazuju odzivnu površinu matematičkog modela za izračun produktivnosti kada u procesu postoji grlo (slika 37) i kada u procesu ne postoji usko grlo (slika 38). Produktivnost je, jasno, veća kada u procesu nema uskog grla. Jasno se i vidi kako se vrijednosti produktivnosti mijenjaju ovisno o koeficijentu varijacije i vremenu trajanja obrade.



Slika 37. 3D prikaz matematičkog modela za izračun produktivnosti ovisno o razini koeficijenta varijacije i vremena *trajanja* obrade slučaju postojanja uskog grla u procesu i za slučaj 3 Conwip kartice po radnom mjestu (15 kartica za cijeli proces)



Slika 38. 3D prikaz matematičkog modela za izračun produktivnosti ovisno o razini koeficijenta varijacije i vremena trajanja obrade slučaju nepostojanja uskog grla u procesu i za slučaj 3 Conwip kartice po radnom mjestu (15 kartica za cijeli proces)

4.4.3.2 Mjerna performansa – vodeće vrijeme

U ovom poglavlju će biti prikazani rezultati dobiveni simulacijskim eksperimentiranjem (Prilog A - 3) u svrhu dobivanja matematičkog modela koji opisuje utjecaj variranih parametara proizvodnog procesa na performansu vodeće vrijeme za slučaj kada je kao mehanizam upravljanja proizvodnim procesom korišten hibrid Kanban/Conwip mehanizam upravljanja.

I u ovom slučaju, prije analize varijance bilo je potrebno napraviti transformaciju podataka, budući je omjer maksimalne i minimalne mjerene vrijednosti veći od 10 [40]. Na taj način je zadovoljena homogenost varijance po eksperimentalnom prostoru [42]. Podaci su transformirani pomoću izraza:

$$y' = \frac{1}{\sqrt{y + k}}, \quad k = 0 \quad (4-27)$$

gdje je:

y' – transformirani podatak

y - stvarni podatak

Analiza varijance prikazana je u tablici 21. F-vrijednost koja iznosi 3 266,36 pokazuje da je postavljeni model značajan. P-vrijednost također ukazuje na značajnost modela. Obzirom da je P-vrijednost manja od 0,05 hipoteza H_0 se odbacuje [41]. Hipoteza H_0 za postavljeni plan pokusa glasi: varijabilnost vremena obrade, vrijeme trajanja operacije, usko grlo te broj Conwip kartica ne utječu na veličinu vodeće vrijeme.

Značajni članovi ovog modela su: A, B, C i D, te interakcije AC, AD, BC, BD, ABC, ABD, ACD i ABCD: Njihova P-vrijednost je manja od 0,05, što je uvjet za značajnost članova modela.

Tablica 21. Analiza varijance matematičkog modela koji opisuje utjecaj variranih parametara na vodeće vrijeme kada se procesom upravlja hibridnim mehanizmom upravljanja

Izvor varijacije	Suma kvadrata odstupanja	Broj stupnjeva slobode	Srednji kvadrat odstupanja	F-vrijednost	P-vrijednost	Značajnost
Model	0,2172	15	0,0145	3266,36	< 0.0001	značajan

Članovi modela						
AB	0,0008	1	0,0008	176,88	< 0.0001	značajan
AC	0,0008	1	0,0008	188,31	< 0.0001	značajan
AD	0,0001	1	0,0001	12,06	0,0009	značajan
BC	0,0063	1	0,0063	1413,99	< 0.0001	značajan
BD	0,0003	1	0,0003	76,65	< 0.0001	značajan
CD	0,0000	1	0,0000	3,53	0,0647	značajan
ABC	0,0005	1	0,0005	119,90	< 0.0001	značajan
ABD	0,0000	1	0,0000	7,72	0,0071	značajan
ACD	0,0003	1	0,0003	72,08	< 0.0001	značajan
BCD	0,0000	1	0,0000	3,85	0,0541	značajan
ABCD	0,0003	1	0,0003	75,05	< 0.0001	značajan
Čista greška	0,0003	64	4,433E-06			
Ukupno	0,2175	79				

Vrijednost predviđenog koeficijenta determinacije, R_{pre}^2 ovog modela a koja iznosi 0,9987 i vrijednost prilagođenog koeficijenta determinacije, R_{adj}^2 koja iznosu 0,9984 iznosu su usklađene (tablica 22). Razlika između prilagođenog i predviđenog koeficijenta determinacije manja od 0,2 [40].

Aдекватна preciznost pokazuje odnos veličine signala u odnosu na šum, a njena vrijednost mora biti veća od 4 [40]. U tablici 22 se vidi da je za ovaj model ta vrijednost 148,9462 što upućuje da se model može koristiti za analizu u eksperimentalnom prostoru.

Tablica 22. Veličine koje opisuju kvalitetu dobivenog matematičkog modela za izračun vodećeg vremena kod upravljanja procesom hibridnim mehanizmom upravljanja

Standardna devijacija, mm	0,0021
Aritmetička sredina, mm	0,0847
Koeficijent varijacije, %	2,49

R2 - koeficijent determinacije	0,9987
Radj2 - prilagođeni koeficijent determinacije	0,9984
Rpre2 - predviđeni koeficijent determinacije	0,9980
Aдекватна preciznost	148,9462

Kako je za transformaciju podataka- korištena inverzija korijena broja, tako i dobiveni matematički model predstavlja matematičku funkciju za izračun vodećeg vremena u obliku recipročne vrijednosti korijena broja. Tako izračunatu vrijednost će biti potrebno transformirati u stvarnu vrijednost varijable vodeće vrijeme. Matematički model u kodiranim vrijednostima glasi:

$$\frac{1}{\sqrt{LT_{hibrid}}} = 0,0846 - 0,0045A - 0,049B - 0,0129C - 0,0042D + 0,0031AB + 0,0032AC + 0,0089BC + 0,002BD - 0,0004CD - 0,0026ABC + 0,0007ABD + 0,002ACD + 0,0005BCD - 0,002ABCD \quad (4-28)$$

Matematički model s kodiranim vrijednostima članova modela iz izraza (4-28) prevodi se u model sa stvarnim vrijednostima članova modela. Matematički model sa stvarnim veličinama u slučaju postojanja uskog grla glasi:

$$\frac{1}{\sqrt{LT_{hibrid-NE}}} = 0,165776 + 0,051133Cv - 0,00188t + 0,010565Br - 0,000927Cvt - 0,039442CvBr - 0,000241tBr + 0,000644CvtBr \quad (4-29)$$

Matematički model sa stvarnim veličinama u slučaju nepostojanja uskog grla glasi:

$$\frac{1}{\sqrt{LT_{hibrid-DA}}} = 0,186511 - 0,052523Cv - 0,002414t - 0,025571Br - 0,000894Cvt + 0,18527CvBr + 0,000368tBr - 0,000331CvtBr \quad (4-30)$$

gdje je:


LT_{hibrid} – vodeće vrijeme procesa kada se za upravljanje proizvodnim procesom koristi hibridni Kanban/Conwip mehanizam upravljanja, min

C_v - koeficijent varijacije

t - vrijeme trajanja operacije, min


Br - broj Conwip kartica na pojedinom radnom mjestu, kom/RM

Slika 39 prikazuje normalizirani papir vjerojatnosti ostataka za pojedino stanje pokusa. Analiza ostataka provodi se pregledom odstupanja ostataka od linije normalne razdiobe. Točke koje predstavljaju ostatke trebaju pratiti liniju normalne razdiobe. Ukoliko to nije slučaj, model treba korigirati. U ovom slučaju vidljivo je da su podaci raspoređeni po normalnoj razdiobi.




Slika 39. Normalizirani papir ostataka za matematički model za izračun vodećeg vremena kod upravljanja procesom hibridnim mehanizmom upravljanja

Dijagram ostataka u odnosu na redoslijed izvođenja plana pokusa provjerava postojanje sustavne pogreške koja je mogla utjecati na odziv tijekom provođenja eksperimenta. Slika 40 prikazuje slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana pokusa na kojoj je vidljivo da ne postoji sustavna pogreška u pozadini, odnosno da se svi podaci nalaze unutar postavljenih granica vjerojatnosti ($\pm 3,58$).




Slika 40. Slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana za matematički model za izračun vodećeg vremena kod upravljanja procesom hibridnim mehanizmom upravljanja

Na slici 41 prikazan je konturni dijagram matematičkog modela za izračun vodećeg vremena u ovisnosti o visini koeficijenta varijacije i u ovisnosti o vremenu trajanja operacije. Veličina "broj Conwip kartica" je u ovom slučaju konstantna i iznosi 2, a u procesu ne postoji usko grlo.




Slika 41. Konturni prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade slučaju nepostojanja uskog grla u procesu i za slučaj 2 Conwip kartice po radnom mjestu

Slika 42 prikazuju 3D prikaz odzivne površine matematičkog modela za vodeće vrijeme, za istu razinu parametara „usko grlo“ i „broj Conwip kartica“. Može se vidjeti kako porastom varijacija u procesu tj. u slučaju više vrijednosti koeficijenta varijacije dužina trajanja vodećeg vremena raste. Cilj poboljšanja proizvodnog procesa je smanjiti ili eliminirati izvore varijacija u procesu kao bi vodeće vrijeme bilo kraće. Također, kada je vrijeme trajanje operacije duže vrijednost vodećeg vremena je također veća.




Slika 42. 3D prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju nepostojanja uskog grla u procesu i za slučaj 2 Conwip kartice po radnom mjestu

Slika 43 prikazuju 3D prikaz odzivne površine matematičkog modela za vodeće vrijeme, za isti broj Conwip kartica, u slučaju kada u procesu postoji usko grlo. Može se vidjeti kako porastom varijacija u procesu tj. u slučaju više vrijednosti koeficijenta varijacije dužina trajanja vodećeg vremena raste. Ako usporedimo ovu odzivnu površinu sa odzivnom površinom na prethodnom 3D prikazu vidljivo je kako su vrijednosti vodećeg vremena više u slučaju postojanja uskog grla.



Slika 43. 3D prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade slučaja postojanja uskog grla u procesu i za slučaj 2 Conwip kartice po radnom mjestu

Ako se usporede odzivne površine na slici 43 i na slici 44 vidi se da u slučaju većeg broja Conwip kartica na radnom mjestu (u prvom slučaju ukupno 10 kartica u procesu tj. 2 kartice prosječno po radnom mjestu, a u drugom slučaju 15 Conwip kartica u procesu, tj i prosjeku 3 kartice po radnom mjestu) vodeće vrijeme raste. Svaka Conwip kartica veže na sebe jedan proizvod ili jednu seriju proizvoda, te sa većim brojem kartica veća je količina rada u procesu što za sobom povlači i duže vodeće vrijeme. Cilj je smanjiti količinu rada u procesu, ali vodeći računa o produktivnosti tj propusnosti procesa, posebno u slučaju varijacija u procesu. Naime, većim brojem kartica tj većim brojem rada u procesu se te varijacije „pokrivaju“ tj ti baferi služe za sigurnost u slučaju zastoja, grešaka ili bilo kojih drugih uzroka varijacija u procesu.



Slika 44. 3D prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju postojanja uskog grla u procesu i za slučaj 3 Conwip kartice po radnom mjestu

4.4.4 Analiza procesa DBR

4.4.4.1 Mjerna performansa - produktivnost

U ovom poglavlju će biti prikazani rezultati analize podataka za opisivanje utjecaja varijabilnost vremena obrade, vremena trajanja operacije, uskog grla i broja kartica na produktivnost proizvodnog procesa u slučaju kada je kao mehanizam upravljanja proizvodnim procesom korišten DBR. Rezultati dobiveni simulacijskim eksperimentiranjem (Prilog A - 4) su obrađeni u svrhu dobivanja matematičkog modela koji opisuje utjecaj variranih parametara proizvodnog procesa na mjernu performansu „produktivnost“.

U tablici analize varijance, može se vidjeti da je postavljeni model značajan na što ukazuje F-vrijednost koja iznosi 1 267 819, 84. Također, P-vrijednost, koja također ukazuje na značajnost modela upućuje na to da se hipoteza H_0 odbacuje. Naime, P-vrijednost treba biti manja od 0,05 za odbacivanje hipoteze H_0 . Hipoteza H_0 za postavljeni plan pokusa glasi: varijabilnost vremena obrade, vrijeme trajanja operacije, usko grlo te broj DBR kartica ne utječu na razinu usluge proizvodnog procesa.

Odstupanje od modela, kako se vidi u tablici nije značajno i njegova F-vrijednost iznosi 1,36. Odstupanje od modela je veličina koja mjeri varijaciju vrijednosti mjerene veličine kod ponavljanja istih stanja pokusa oko njihove srednje vrijednosti. Ako je ta veličina značajna to znači da model nedovoljno dobro opisuje pojavu.

Značajni članovi modela su A, B, C i D, te interakcije AB, AC, AD i BC jer su njihove p-vrijednosti manje od 0,05.

Tablica 23. Analiza varijance matematičkog modela koji opisuje utjecaj variranih parametara na produktivnost kada se procesom upravlja DBR mehanizmom upravljanja

Izvor varijacije	Suma kvadrata odstupanja	Broj stupnjeva slobode	Srednji kvadrat odstupanja	F-vrijednost	P-vrijednost	Značajnost
Model	1 897,72	8	237,21	$1,126 \times 10^6$	$< 0,0001$	značajan
Članovi modela						
A	2,61	1	2,61	14 245,47	$< 0,0001$	značajan
B	1 811,56	1	1 811,56	$9,886 \times 10^6$	$< 0,0001$	značajan
C	45,74	1	45,74	$2,496 \times 10^5$	$< 0,0001$	značajan

D	0,0025	1	0,0025	13,39	0,0005	značajan
AB	0,1530	1	0,1530	835,16	< 0,0001	značajan
AC	0,1313	1	0,1313	716,53	< 0,0001	značajan
AD	0,0030	1	0,0030	16,61	0,0001	značajan
BC	37,52	1	37,52	$2,048 \times 10^5$	< 0,0001	značajan
Ostatak	0,0133	71	0,0002			
Odstupanje od modela	0,0017	7	0,0002	1,36	0,2362	nije značajno
Čista greška	0,0116	64	0,0002			
Ukupno	1 897,73	79				

Vrijednost predviđenog koeficijenta determinacije, R_{pre}^2 i prilagođenog koeficijenta determinacije, R_{adj}^2 su u dobrom odnosu. Razlika između prilagođenog i predviđenog koeficijenta determinacije manja od 0,2. To znači da je dobiveni regresijski model (odzivna funkcija) različit od slučajnih pojava

Vrijednost adekvatne preciznosti je veća od 4 što upućuje da se model može koristiti u eksperimentalnom prostoru.

Tablica 24. Veličine koje opisuju kvalitetu dobivenog matematičkog modela za izračun produktivnosti kod upravljanja procesom DBR mehanizmom upravljanja

Standardna devijacija, mm	0,0137
Aritmetička sredina, mm	5,47
Koeficijent varijacije, %	0.2499
R^2 - koeficijent determinacije	0,999
R_{adj}^2 - prilagođeni koeficijent determinacije	0,999
R_{pre}^2 - predviđeni koeficijent determinacije	0,999
Adekvatna preciznost	2 485,453

Matematički model dobiven regresijskom analizom definira zavisnost između dviju ili više varijabli. Temeljem rezultata dobivenih simulacijskim eksperimentiranjem procijenjeni su koeficijenti matematičkog (regresijskog) modela. Prvo je postavljen je matematički model za izračun produktivnosti ovisno o utjecajnim parametrima u kodiranim vrijednostima:

$$P_{dbr} = 5,48 - 0,1830A - 4,76B - 0,7561C + 0,0086D + \\ + 0,0468AB + 0,0404AC + 0,0032AD + 0,6854BC \quad (4-31)$$

Matematički model s kodiranim vrijednostima članova modela iz izraza (4-30) prevodi se u model sa stvarnim vrijednostima članova modela. Dobiveni matematički model u slučaju kada u procesu postoji usko grlo glasi:

$$P_{dbr-DA} = 9,88346 - 0,696599Cv - 0,151325t - 0,004601Br + 0,005583Cvt \\ + 0,016574CvBr \quad (4-32)$$

Dobiveni matematički model u slučaju kada u procesu ne postoji usko grlo glasi:

$$P_{dbr-NE} = 13,16724 - 0,961586Cv - 0,201172t + 0,004601Br + 0,005583Cvt \\ + 0,016574CvBr \quad (4-33)$$

gdje je:


P_{dbr} – produktivnost proizvodnog procesa kada se za upravljanje proizvodnim procesom koristi DBR mehanizam upravljanja, kom/h

Cv - koeficijent varijacije

t - vrijeme trajanja operacije, min


Br - broj DBR kartica na pojedinom radnom mjestu, kom/RM

Normalizirani papir vjerojatnosti ostataka ispituje normalnost izmjerenih vrijednosti za pojedina stanja pokusa. Slika 45 prikazuje normalizirani papir vjerojatnosti ostataka za pojedino stanje pokusa. Analiza ostataka provodi se pregledom odstupanja ostataka od linije normalne razdiobe. Točke koje predstavljaju ostatke trebaju pratiti liniju normalne razdiobe. Ukoliko to nije slučaj, model treba korigirati. U ovom slučaju vidljivo je da su podaci raspoređeni po normalnoj razdiobi.




Slika 45. Normalizirani papir ostataka za matematički model za izračun produktivnosti kod upravljanja procesom DBR mehanizmom upravljanja

Dijagram ostataka u odnosu na redoslijed izvođenja plana pokusa provjerava postojanje sustavne pogreške koja je mogla utjecati na odziv tijekom provođenja eksperimenta. Slika 46 prikazuje slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana pokusa na kojoj je vidljivo da ne postoji sustavna pogreška u pozadini, odnosno da se svi podaci nalaze unutar postavljenih granica vjerojatnosti ($\pm 3,58$).




Slika 46. Slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana za matematički model za izračun produktivnosti kod upravljanja procesom DBR mehanizmom upravljanja

Na slici 47 prikazan je konturni dijagram matematičkog modela za izračun produktivnosti u ovisnosti o visini koeficijenta varijacije i u ovisnosti o vremenu trajanja operacije. Veličina “broj DBR kartica” je konstantna i iznosi 3,5, a u procesu ne postoji usko grlo. Konturne krivulje imaju pad sa porastom koeficijenta varijacije. Dakle, porastom varijacija u procesu razina produktivnosti opada.




Slika 47. Konturni prikaz matematičkog modela za izračun produktivnosti ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju nepostojanja uskog grla u procesu i za slučaj 3,5 DBR kartice po radnom mjestu (14 DBR kartica za cijeli proces)

Slike 48 i 49 prikazuju 3D prikaz odzivne površine matematičkog modela za izračun produktivnosti, za isti broj DBR kartica (3,5, odnosno ukupno 14 kartica u procesu). Slika 48 prikazuje slučaj kada u procesu ne postoji usko grlo, a slika 49 prikazuje slučaj kada u procesu postoji usko grlo. Može se vidjeti kako je vrijednost produktivnosti veća kada u procesu ne postoji usko grlo.



Slika 48. 3D prikaz matematičkog modela za izračun produktivnosti ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju nepostojanja uskog grla u procesu i za slučaj 3,5 DBR kartice po radnom mjestu (14 DBR kartica za cijeli proces)



Slika 49. 3D prikaz matematičkog modela za izračun produktivnosti ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju postojanja uskog grla u procesu i za slučaj 3,5 DBR kartice po radnom mjestu (14 DBR kartica za cijeli proces)

4.4.4.2 Mjerna performansa – vodeće vrijeme

U ovom poglavlju će biti prikazani rezultati analize podataka za opisivanje utjecaja varijabilnost vremena obrade, vremena trajanja operacije, uskog grla i broja kartica na vodeće vrijeme proizvodnog procesa za slučaj kada je kao mehanizam upravljanja proizvodnim procesom korišten DBR. Rezultati dobiveni simulacijskim eksperimentiranjem (Prilog A - 4) su obrađeni u svrhu dobivanja matematičkog modela koji opisuje utjecaj variranih parametara proizvodnog procesa na mjernu performansu vodeće vrijeme.

Prije analize varijance bilo je potrebno napraviti transformaciju podataka. Naime, na ovom skupu podataka omjer maksimalne i minimalne mjerene vrijednosti je veći od 10, pa je u tom slučaju potrebna transformacija [40]. Na taj način je zadovoljena homogenost varijance po eksperimentalnom prostoru [42]. Podaci su transformirani prema izrazu (4-27).

Obzirom na F-vrijednost i P-vrijednost koje su prikazane u tablici 25 analize varijance, model je značajan [40]. P-vrijednost treba biti manja od 0,05 za odbacivanje hipoteze H_0 . Hipoteza H_0 za postavljeni plan pokusa glasi: varijabilnost vremena obrade, vrijeme trajanja operacije, usko grlo te broj DBR kartica ne utječu na vodeće vrijeme proizvodnog procesa.

Također, P-vrijednosti za članov modela upućuju da su članovi modela A, B, C i D, te interakcije AB, AD, BC, BD, CD, ABD i BCD značajni parametri modela.

Odstupanje od modela, kako se vidi u tablici 25 nije značajno i njegova F-vrijednost iznosi 3,24. Odstupanje od modela je veličina koja mjeri varijaciju vrijednosti mjerene veličine kod ponavljanja istih stanja pokusa oko njihove srednje vrijednosti. Ako je ta veličina značajna to znači da model nedovoljno dobro opisuje pojavu. Ovdje se može zaključiti kako matematički model dovoljno dobro opisuje pojavu.

Tablica 25. Analiza varijance matematičkog modela koji opisuje utjecaj variranih parametara na produktivnost kada se procesom upravlja DBR mehanizmom upravljanja

Izvor varijacije	Suma kvadrata odstupanja	Broj stupnjeva slobode	Srednji kvadrat odstupanja	F-vrijednost	P-vrijednost	Značajnost
Model	0,2142	14	0,0153	3 103,46	< 0,0001	značajan
Članovi						

A	0,0018	1	0,0018	365,87	< 0,0001	značajan
B	0,1871	1	0,1871	37947,93	< 0,0001	značajan
C	0,0142	1	0,0142	2882,65	< 0,0001	značajan
D	0,0011	1	0,0011	225,04	< 0,0001	značajan
AB	0,0011	1	0,0011	213,46	< 0,0001	značajan
AC	0,0007	1	0,0007	141,21	< 0,0001	značajan
AD	$9,415 \times 10^8$	1	$9,415 \times 10^8$	0,0191	0,8905	značajan
BC	0,0064	1	0,0064	1289,18	< 0,0001	značajan
BD	0,0002	1	0,0002	43,31	< 0,0001	značajan
CD	0,0009	1	0,0009	178,52	< 0,0001	značajan
ABC	0,0005	1	0,0005	99,98	< 0,0001	značajan
ABD	0,0000	1	0,0000	7,92	0,0065	
ACD	0,0000	1	0,0000	3,65	0,0606	
BCD	0,0002	1	0,0002	49,68	< 0,0001	
Ostatak	0,0003	65	4,930E-06			
Odstupanje od modela	0,0000	1	0,0000	3,24	0,0766	nije značajno
Čista greška	0,0003	64	4,766E-06			
Ukupno	0,2145	79				

Razlika između prilagođenog i predviđenog koeficijenta determinacije je manja od 0,2 (tablica 26). To pokazuje da je dobiveni regresijski model različit od slučajnih pojava [42].

Aдекватна preciznost pokazuje omjer signal-šum, a njena vrijednost mora biti veća od 4 [40]. U tablici se vidi da je za ovaj model ta vrijednost 147,936 što upućuje da se model može koristiti u eksperimentalnom prostoru.

Tablica 26. Veličine koje opisuju kvalitetu dobivenog matematičkog modela za izračun produktivnosti kod upravljanja procesom DBR mehanizmom upravljanja

Standardna devijacija, mm	0,0022
Aritmetička sredina, mm	0,0842
Koeficijent varijacije, %	2,64
R^2 - koeficijent determinacije	0,9985
R_{adj}^2 - prilagođeni koeficijent determinacije	0,9982
R_{pre}^2 - predviđeni koeficijent determinacije	0,9977
Aдекватna preciznost	147,9360

Kako je za transformaciju podataka- korištena inverzija korijena broja, tako i dobiveni matematički model predstavlja matematičku funkciju za izračun vodećeg vremena u obliku recipročne vrijednosti korijena broja. Tako izračunatu vrijednost će biti potrebno transformirati u stvarnu vrijednost varijable vodeće vrijeme. Matematički model u kodiranim vrijednostima glasi:

$$\begin{aligned} \frac{1}{\sqrt{LT_{dbr}}} = & 0,0842 - 0,0047A - 0,0484B - 0,0133C - 0,0037D + 0,0036AB \\ & + 0,0029AC + 0,0089BC + 0,0016BD - 0,0033CD - 0,025ABC \\ & + 23,87ABD + 0,0005ACD + 54,73BCD \end{aligned} \quad (4-34)$$

Matematički model s kodiranim vrijednostima članova modela iz izraza (4-34) prevodi se u model sa stvarnim vrijednostima [41]. Za slučaj kada u procesu ne postoji usko grlo matematički model glasi:

$$\begin{aligned} \frac{1}{\sqrt{LT_{dbr-NE}}} = & 0,196219 - 0,053698Cv - 0,00268t + 0,001356Br + 0,001111Cvt \\ & + 0,001664CvBr + 0,000067tBr - 0,000133CvtBr \end{aligned} \quad (4-35)$$

Matematički model za slučaj kada u procesu postoji usko grlo glasi:

$$\frac{1}{\sqrt{LT_{dbr-DA}}} = 0,184555 - 0,029414Cv - 0,002289t - 0,021347Br + 0,00052Cvt + 0,006637CvBr + 0,000271tBr - 0,000133CvtBr \quad (4-36)$$

gdje je:


LT_{dbr} – vodeće vrijeme kada se za upravljanje proizvodnim procesom koristi DBR mehanizam upravljanja, kom/h

Cv - koeficijent varijacije

t - vrijeme trajanja operacije, min


Br - broj DBR kartica na pojedinom radnom mjestu, kom/RM

Normalizirani papir vjerojatnosti ostataka ispituje normalnost izmjerenih vrijednosti za pojedina stanja pokusa. Slika 50 prikazuje normalizirani papir vjerojatnosti ostataka za pojedino stanje pokusa. U ovom slučaju vidljivo je da su podaci raspoređeni po normalnoj razdiobi.




Slika 50. Normalizirani papir ostataka za matematički model za izračun produktivnosti kod upravljanja procesom DBR mehanizmom upravljanja

Dijagram ostataka u odnosu na redoslijed izvođenja plana pokusa provjerava postojanje sustavne pogreške koja je mogla utjecati na odziv tijekom provođenja eksperimenta. Slika 51 prikazuje slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana pokusa na kojoj je vidljivo da ne postoji sustavna pogreška u pozadini, odnosno da se svi podaci nalaze unutar postavljenih granica vjerojatnosti ($\pm 3,58$).




Slika 51. Slučajno rasipanje ostataka u odnosu na redoslijed izvođenja plana za matematički model za izračun produktivnosti kod upravljanja procesom DBR mehanizmom upravljanja

Na slici 52 prikazan je konturni dijagram matematičkog modela za izračun vodećeg vremena u ovisnosti o visini koeficijenta varijacije i u ovisnosti o vremenu trajanja operacije. Veličine “usko grlo” i “broj DBR kartica” su u ovom slučaju konstantne i iznose redom 1 i 2.




Slika 52. Konturni prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade slučaju nepostojanja uskog grla u procesu i za slučaj 2,5 DBR kartice po radnom mjestu (9 DBR kartica za cijeli proces)

Na konturnim dijagramima koji su prikazani na slikama 53 i 54 se jasno vidi kako se vodeće vrijeme se povećava ukoliko u procesu postoji jedna operacija koja je usko grlo, a sve ostale operacije jednako traju kao u procesu koji nema usko grlo




Slika 53. Konturni prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade slučaju postojanja uskog grla u procesu i za slučaj 2,5 DBR kartice po radnom mjestu (9 DBR kartica za cijeli proces)




Slika 54. Konturni prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju postojanja uskog grla u procesu i za slučaj 3,5 DBR kartice po radnom mjestu (14 DBR kartica za cijeli proces)

Na 3D prikazu odzivnih površina matematičkog modela vidljivo je kako sa povećanjem broja DBR kartica raste i vrijednost vodećeg vremena. (slike 55 i 56).



Slika 55. 3D prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju postojanja uskog grla u procesu i za slučaj 2,25 DBR kartice po radnom mjestu (9 DBR kartica za cijeli proces)




Slika 56. 3D prikaz matematičkog modela za izračun vodećeg vremena ovisno o razini koeficijenta varijacije i vremena trajanja obrade u slučaju postojanja uskog grla u procesu i za slučaj 3,5 DBR kartice po radnom mjestu (14 DBR kartica za cijeli proces)

5. ANALIZA REZULTATA ISTRAŽIVANJA

Kao što je i bila početna pretpostavka, rezultati simulacijskog eksperimentiranja pokazali su da u različitim uvjetima proizvodni proces postiže različite razine mjera performansi, ovisno koji od mehanizama upravljanja je korišten u tom procesu. Također je potvrđeno da za istu razinu ulaznih utjecajnih parametara pojedini mehanizmi upravljanja doprinose boljim vrijednostima mjernih performansi proizvodnog procesa te su u tom smislu bolji odabir.

Za bolje razumijevanje, u nastavku je prikazan odnos performansi proizvodnog procesa ovisno o mehanizmu upravljanja. Slika 57 pokazuje odnos vrijednosti mjerne performanse produktivnost za pojedine mehanizme upravljanja u slučaju kada u procesu ne postoji usko grlo i kada je razina varijabilnosti vremena trajanja operacija visoka a vrijeme obrade iznosi 5 minuta. Broj upravljačkih kartica za svaki mehanizam upravljanja je utvrđen na način da je prosječna vrijednost rada u procesu jednaka 15. Taj broj je utvrđen heuristički, na način da je provedena simulacija za više različitih razina broja kartica te je utvrđen broj pri kojem proces prosječno ima 15 komada materijala u procesu.




Slika 57. Usporedba mjerne performanse produktivnost za $C_v=0,86$, $t=5$ min za proces koji nema usko grlo, $WIP=15$

Vidljivo je da u ovom slučaju, ukoliko je proizvodni proces upravljan pomoću hibridno Kanban/Conwip mehanizma upravljanja, razina produktivnosti je najviša. Neznatno niža razina usluge se postiže sa Conwip i DBR mehanizmom upravljanja. Najlošiji rezultati su

kod procesa upravljanim Kanban mehanizmom upravljanja. Ovakvi rezultati imaju smisla. Naime, ovdje je riječ o procesu koji je prilično nestabilan, budući da vrijeme trajanja operacije ima visoku varijabilnost. Iz literature je poznato da je jedan od preduvjeta za uspješnu implementaciju Kanbana-a u upravo stabilan proces, pa stoga nije iznenađujuće da je produktivnost kod procesa upravljanim Kanbanom niska, u ovom slučaju najniža. Drugi mehanizmi, redom, Conwip, hibrid Kanban/Conwip te DBR pokazuju puno bolje rezultate.


Također, ovdje je bitno i uočiti ponašanje procesa upravljanim DBR mehanizmom upravljanja. Naime, u literaturi se ovaj mehanizam navodi kao superioran u procesima koji imaju usko grlo, no pregledom literature nije pronađeno da je do sada istraženo kakvi rezultati se postižu ukoliko se ovaj mehanizam upravljanja implementira u procesu koji nema usko grlo. Kao što je vidljivo na slici 66, produktivnost, u navedenim zadanim uvjetima je viša kod procesa upravljanim DBR mehanizmom nego Kanban mehanizmom upravljanja.

Za istu kombinaciju parametra, jedino uz promjenu da postoji usko grlo u procesu, prikazan je odnos vrijednosti produktivnosti proizvodnog procesa za pojedine mehanizme upravljanja (slika 58). Također, usporedba je rađena na način da je broj upravljačkih kartica za svaki mehanizam upravljanja utvrđen kako bi prosječna vrijednost rada u procesu bila jednaka 15. Taj broj je utvrđen heuristički, na način da je provedena simulacija za više različitih razina broja kartica te je utvrđen broj pri kojem proces prosječno ima 15 komada materijala u procesu.




Slika 58. Usporedba mjerne performanse produktivnost za $C_v=0,86$, $t=5$ min za proces koji ima usko grlo, $WIP=15$

Na slici 58 može se vidjeti kako je DBR mehanizam upravljanja u ovom slučaju, tj. za ove postavke razina parametara proizvodnje, dakle visoku razinu varijabilnosti, postojanje uskog grla, te vrijeme obrade 5 minuta, superioran naspram druga tri mehanizma. Taj rezultat je opet očekivan, i potvrđuje sva dosadašnja istraživanja o DBR mehanizmu upravljanja.




Slika 59. Usporedba mjerne performanse produktivnost za $C_v=0,25$, $t=5$ min za proces koji nema usko grlo, $WIP=15$

Slike 59 i 60 prikazuju odnos produktivnosti u slučaju niže varijabilnosti vremena trajanja operacija. Vidi se da su u procesu bez uskog grla još uvijek hibridni i Conwip mehanizam upravljanja bolji no razlika je puno manja. U procesu koji ima usko grlo najveća produktivnost se postiže sa DBR mehanizmom upravljanja. Iako su varijacije u proizvodnom procesu manje (niža vrijednost koeficijenta varijacije za vrijeme trajanja obrade) DBR mehanizam je i dalje najbolji odabir.




Slika 60. Usporedba mjerne performanse produktivnost za $C_v=0,25$, $t=5$ min za proces koji ima usko grlo, $WIP=15$

Slika 61 prikazuje odnos produktivnosti u slučaju niže varijabilnosti vremena trajanja operacija, ali za slučaj kada operacije traju 60 minuta. U ovom slučaju hibridni mehanizam bi bio najbolji odabir.




Slika 61. Usporedba mjerne performanse Produktivnost za $C_v=0,25$, $t=60$ min za proces koji nema usko grlo

Na slikama 62 i 63 prikazan je odnos mjerne performanse vodeće vrijeme za sva četiri mehanizma upravljanja u slučaju niže varijabilnosti vremena trajanja operacija. U slučaju kada u procesu ne postoji usko grlo, proces upravljan Kanbanom će kod visoke varijabilnosti imati najduže vodeće vrijeme dok kod niže varijabilnosti to nije slučaj. To je u skladu i sa, u poglavlju 3 spomenutim preduvjetima za uspješnu primjenu Kanbana a to je stabilan proizvodni proces tj. proces sa što manje varijacija u procesu.




Slika 62. Usporedba mjerne performanse vodeće vrijeme za $C_v=0,25$, $t=40$ min za proces koji nema usko grlo, $WIP=15$




Slika 63. Usporedba mjerne performanse vodeće vrijeme za $C_v=0,25$, $t=40$ min za proces koji ima usko grlo, $WIP=15$

Na slikama 64 i 65 odnos vodećeg vremena za slučaj veće varijabilnost u procesu.




Slika 64. Usporedba mjerne performanse vodeće vrijeme za $C_v=0,86$, $t=40$ min za proces koji nema usko grlo, $WIP=15$

U slučaju postojanja uskog grla DBR mehanizam upravljanja nije najbolji odabir ako se želi postići najkraće vodeće vrijeme (slike 65 i 66) dok za slučaj mjerne performanse produktivnost, DBR je najbolji odabir (slike 58, 60 i 62). U ovom slučaju, možda je bolji odabir mehanizam s kojim se postiže nešto niža produktivnost ali kraće vodeće vrijeme.



Slika 65. Usporedba mjerne performanse vodeće vrijeme za $C_v=0,86$, $t=40$ min za proces koji ima usko grlo, $WIP=15$


Na prethodnim prikazima usporebni mehanizama upravljanja (slika 57 do slika 65) mehanizmi su uspoređivani u slučaju jednakog broja upravljačkih kartica, odnosno u slučaju jednake količine rada u procesu. Na taj je način usporedba ujednačena u smislu istih uvjeta u proizvodnom procesu, obzirom da se promjenom broja upravljačkih kartica mijenja i razina produktivnosti. Na koji način razina produktivnosti ovisi o broju kartica (kanban, conwip i dbr kartica) u procesu prikazano je na slikama 66 i 67.



Slika 66. Usporedba mjerne performanse produktivnost u ovisnosti o broju upravljačkih kartica za $C_v=0,25$, $t=60$ min za proces koji ima usko grlo

Na slici 66 dana je usporedba produktivnosti za sva četiri mehanizma upravljanja u ovisnosti o broju kartica po radnom mjestu. Slika 66 prikazuje slučaj kada koeficijent varijabilnosti iznosi 0,25, vrijeme obrade je 60 minuta a u procesu postoji usko grlo. Za ovakav proces najveća produktivnost se postiže DBR mehanizmom upravljanja, no međutim u slučaju prosječno jedne kartice po radnom mjestu u procesu, veća produktivnost se postiže Conwip mehanizmom upravljanja. U idućem poglavlju biti će prikazano kako broj kartica utječe na duljinu trajanja vodećeg vremena te da se najkraće vodeće vrijeme postiže sa minimalnim brojem upravljačkih kartica. To je i razumljivo, budući da veći broj upravljačkih kartica znači i više rada u procesu a to onda utječe i na povećanje vodećeg vremena. U kontekstu usporedbe prikazane na slici 66 može se zaključiti da ukoliko poduzeće želi postići najkraće vodeće vrijeme u ovim uvjetima Conwip bi bio bolji odabir nego DBR. Za slučaj

cilja postizanja što veće produktivnosti a na uštrb trajanja vodećeg vremena bolji odabir bi bio DBR mehanizam upravljanja.



Slika 67. Usporedba mjerne performanse produktivnost u ovisnosti o broju upravljačkih kartica za $C_v=0,25$, $t=60$ min za proces koji nema usko grlo

Na slici 67 dana je usporedba produktivnosti za sva četiri mehanizma upravljanja u ovisnosti o broju kartica po radnom mjestu za slučaj kada koeficijent varijabilnosti iznosi 0,25, vrijeme obrade je 60 minuta a u procesu ne postoji usko grlo. U ovom slučaju, kada u procesu ne postoji usko grlo najveću produktivnost može postići proces kojim se upravlja hibridnim mehanizmom upravljanja. Za veći broj kartica u procesu produktivnost koja se postiže upravljanjem pomoću Conwip mehanizma upravljanja se približava razini produktivnosti koja se postiže Hibridnim mehanizmom upravljanja.

Rezultati prikazani u ovom poglavlju mogu se primijeniti u praksi, kao smjernice za odabir mehanizma upravljanja proizvodnjom u ovisnosti o stanju proizvodnog sustava i vrijednosti performansi proizvodnje koje se žele postići. S tim ciljem definiran je algoritam za donošenje odluke koji mehanizam upravljanja proizvodnjom odabrati, koji se sastoji iz slijedećih koraka:

- Korak 1: Definirati trenutno stanje proizvodnog procesa kroz parametre koeficijent varijabilnosti vremena obrade, vrijeme trajanja obrade i da li u procesu postoji usko grlo.
- Korak 2: Definirati ciljeve koji se žele postići – visoka produktivnost, najkraće vodeće vrijeme ili kompromis između oba kriterija
- Korak 3: Pronaći optimalno rješenje pomoću matematičkih modela dobivenih u poglavlju 4.4.

Ovim postupkom moguće je odrediti odnose između četiri mehanizma upravljanja (Kanban, Conwip, hibrid Kanban/Conwip) pri različitim nivoima utjecajnih parametara i različitim postavljenim ciljevima (produktivnost i vodeće vrijeme). Rezultati su ograničeni na procese u kojima je omjer duljine trajanja uskog grla i operacija koje nisu usko grlo 1:1,33, te se u budućim znanstvenim istraživanjima može usporediti taj odnos za različite omjere duljine trajanja uskog grla i ostalih operacija. Također, na vrijednost vodećeg vremena utječe i ukupan broj radnih mjesta u procesu, što primjenu ovog modela ograničava na takav proizvodni proces, no cilj istraživanja nije bio odrediti točan iznos vodećeg vremena ili produktivnosti već odrediti odnose tih veličina za različite mehanizme upravljanja, a pregledom literature je utvrđeno kako model od pet radnih stanica može dovoljno dobro predstavljati različite stvarne ili hipotetske proizvodne procese i odnose u njima [20], [34], [35], [36]. U idućem poglavlju biti će prikazano kako su ove smjernice primjenjive i na proces koji se sastoji od 15 radnih mjesta.

6. PRIMJENA REZULTATA ISTRAŽIVANJA

Voditelji proizvodnje i svi drugi koji se bave upravljanjem proizvodnim procesima često nemaju vremena testirati koji mehanizam upravljanja koristiti u svom proizvodnom procesu. Prilikom implementacije principa Vitke proizvodnje u poduzeću, u fazi projekta kada se uvodi princip povlačenja u proizvodni proces postavlja se pitanje koji mehanizam upravljanja primijeniti. Kako je već u prethodnim poglavljima spomenuto prvi mehanizam upravljanja koji je potekao iz Toyotinih pogona, gdje su i nastali i razvijali se principi Vitke proizvodnje, bio je Kanban. Za uspješnu implementaciju Kanbana s vremenom su se iskristalizirali i uvjeti koji trebaju biti ostvareni u proizvodnom procesu kako bi implementacija Kanbana dala očekivane rezultate. Ti uvjeti su prije svega stabilan proces, bez zastoja, grešaka, sa kratkim vremenima namještanja stroja itd. Zanimljivo je i spomenuti kako je u prvim fazama primjene Kanbana Toyoti trebalo i nekoliko godina da Kanban zaživi kao način upravljanja proizvodnjom. Vremenom, kakao se primjena principa Vitke proizvodnje proširila svijetom, u mnogim proizvodnim poduzećima, razvijali su se i drugi mehanizmi upravljanja a najznačajniji od njih su analizirani u ovom radu. Iz sveg gore navedenog može se zaključiti kako je korisno imati smjernice koji mehanizam upravljanja implementirati obzirom za trenutne prilike u pogonu i performanse koje se žele postići. U tom smislu rezultati ovog istraživanja mogu pomoći u odabiru mehanizma upravljanja u proizvodnom procesu obzirom na parametre varijabilnost vremena obrade i postojanje uskog grla u procesu, te obzirom na kriterije koji se žele postići, a to su visoka produktivnost ili minimalno vodeće vrijeme ili kompromis između oba kriterija.

6.1 Testiranje na odabranom modelu

Za testiranje dobivenih rezultata korišten je proizvodni proces iz članka *A comparative study of production control mechanisms using simulation-based multi-objective optimization* [11]. Proizvodni proces se sastoji iz 15 radnih stanica. Vrijeme trajanja operacija na svakoj radnoj stanici iznosi 4 minute, osim na stanici broj 8, na kojoj je vrijeme trajanja operacije 6 minuta i ona predstavlja usko grlo.

Kako je model preuzet iz drugog znanstvenog rada na početku je bilo potrebno validirati izrađeni model. U prvoj fazi model je validiran usporedbom sa matematičkim

rezultatima. Kao matematička referenca korišten je Littlov zakon, zakon koji je nastao na temelju osnovne teorije repova a koji opisuje odnos propusnosti, rada u procesu i proizvodnog ciklusa (vodećeg vremena).

Littlov zakon glasi

$$TH = \frac{WIP}{LT} \quad (6-1)$$

pri čemu je:

TH ... propusnost (eng. Throughput), kom/h

WIP ... količina rada u procesu, kom

LT ... vodeće vrijeme, h

Simulacijski model je izrađen kako je opisan u navedenom članku. U prvoj fazi testiranja model nema nikakve varijacije u procesu, dakle, vrijeme trajanja operacija je fiksno zadano, redom kako je proces opisan u članku, bez uskog grla. Vrijeme trajanja svake operacije iznosi 4 minute. Zatim je simulirana proizvodnja u trajanju od 117 000 radnih sati. Mjerne performanse koje su praćene jesu redom vodeće vrijeme, rad u procesu i propusnost kako bi se valjanost istih mogao provjeriti kroz usporedbu sa vrijednostima dobivenim matematičkim izračunom prema Littlovom zakonu. Dobivene vrijednosti simulacijom i matematičkim izračunom prikazane su u tablici 13.

Proizvodni proces koji je simuliran sastoji se od 15 radnih stanica. Vrijeme trajanja obrade na svakoj stanici iznosi 4 minute. U idealnom uvjetima, bez varijacija u procesu, dakle bez ikakvih zastoja i čekanja vrijeme potrebno materijalu da prođe kroz proces iznosi:

$$LT = 15 \times 4 \text{ min} = 60 \text{ min} = 1 \text{ h}$$

Također, u idealnim uvjetima, između radnih mjesta nema bafera tako da ukupni rad u procesu iznosi:

WIP= 15 kom

Prema Littlovom zakonu propusnost procesa iznosi:

$$TH = \frac{WIP}{LT} = \frac{15}{1} = 15 \text{ kom/h}$$

Tablica 27. Usporedba rezultata dobivenih simulacijom sa rezultatima dobivenim matematičkim izračunom

	Rezultati simulacije	Rezultati – Littlov zakon
Vodeće vrijeme [h]	1	1
Rad u procesu [kom]	15	15
Propusnost [kom/h]	14,998	15

Prema dobivenim rezultatima, danim u tablici 27, može se zaključiti da je proizvodni proces dobro modeliran. Validacija je, dakle, uspješna.

U drugoj fazi validacije uzeto je u obzir da proizvodni proces ima usko grlo. Usko grlo se nalazi na radnom mjestu broj 12 i vrijeme obrade na tom radnom mjestu iznosi 6 minuta. Proces je kao i u prethodnoj simulaciji potpuno stabilan, bez ikakvih zastoja, čekanja, dakle bez ikakvih varijacija u procesu. Očitane vrijednosti mjernih performansi dane su u tablici 28.

Tablica 28. Rezultati dobiveni simulacijom za proces koji ima usko grlo

	Rad u procesu, prosječno [kom]	Vodeće vrijeme, prosječno [h]	Propusnost, prosječno [kom/h]
Proces sa uskim grlom	134	13,4	9,99

Ukoliko dobivene vrijednosti za rad u procesu i vodeće vrijeme provjerimo putem Littlovog zakona rezultati će biti slijedeći:

$$TH = \frac{WIP}{LT} = \frac{134}{13,4} = 10 \text{ kom/h}$$

Dobivena propusnost odgovara onoj očitanoj iz simulacijske studije (tablica 28), dakle, može se zaključiti kako je proces dobro modeliran.

U trećoj fazi validacije u proces je uključena i varijabilnost prema karakteristikama opisanim u navedenom članku, tako da je sada proces u potpunosti modeliran prema modelu iz članka. Ovo su karakteristike procesa:

1. Vrijem trajanja operacija nije stalno te su sve greške i zastoji definirani kroz koeficijent varijacije vremena trajanja operacija. Korištena je log-normalna distribucija
2. Vrijeme trajanja operacija iznosi 4 minute, osim na radnim mjestu broj 12 koje je usko grlo i gdje je vrijeme trajanja operacije 6 minuta
3. Materijal pristiže na prvo radno mjesto bez ikakvih zastoja ili čekanja tj. materijal je radnom mjestu 1 uvijek dostupan
4. Gotov proizvod ide u skladište gotovih proizvoda od kud ga kupac može preuzeti
5. Proizvodni proces funkcionira po principu *push*
6. Performansa procesa koja se promatra je produktivnost

U tablici 29 prikazan su rezultati dobiveni simulacijom i rezultati iz članka. Vidi se da se rezultati podudaraju tj razlika je minimalna i može se smatrati zanemarivom. Ovo je još jedna potvrda da je odabrani proizvodni proces dobro modeliran te je sada moguće na ovom simulacijskom modelu nastaviti daljnja istraživanja.

Tablica 29. Usporedba rezultata dobivenih simulacijom sa rezultatima iz članka [11]

	Rezultati simulacije	Rezultati – članak	Razlika	Razlika [%]
Produktivnost [kom/h]	9,35	9,5	0,15	1,6

U daljnjem tekstu slijedi opis testiranja rezultata dobivenih prethodnim istraživanjem a koji su opisani u poglavljima 4. i 5. Testiranje je izvršeno prema koracima opisanim u poglavlju 5:

Korak 1 – Definiranje trenutnog stanja:

- Koeficijent varijabilnosti vremena obrade, $C_v=1,5$
- Vrijeme trajanja operacije, $t=4\text{min}$
- Postojanje uskog grla - Da

Korak 2 – Definiranje ciljeva:

- Minimalno vodeće vrijeme

Korak 3 – Pronaći optimalno rješenje

Za problem opisan kroz korake 1, 2 i 3 postavlja se slijedeći problem nelinearnog programiranja:

$$\ln(LT_{\text{Kanban-DA}}) = 3,17249 + 0,244123C_v + 0,052751t - 0,0327Br - 0,001974C_vt \\ + 0,195583C_vBr \rightarrow \min$$

$$(LT_{\text{Conwip-DA}})^{0,25} = 1,47958 + 0,282961C_v + 0,039774t + 0,454797Br + 0,012985C_vt \\ - 0,034308C_vBr + 0,004261tBr - 0,005601C_vtBr \rightarrow \min$$

$$\frac{1}{\sqrt{LT_{\text{hibrid-DA}}}} = 0,186511 - 0,052523C_v - 0,002414t - 0,025571Br + 0,000894C_vt \\ + 0,18527C_vBr + 0,000368tBr - 0,000331C_vtBr \rightarrow \min$$

$$\frac{1}{\sqrt{LT_{\text{dbr-DA}}}} = 0,184555 - 0,029414C_v - 0,002289t - 0,021347Br + 0,00052C_vt \\ + 0,006637C_vBr + 0,000271tBr - 0,000133C_vtB \rightarrow \min$$

Uz ograničenja:

- (1) $C_v = 1,5$
- (2) $t=4$
- (3) $Br \geq 1$

Za postavljene funkcije cilja i ograničenja pronađena su optimalna rješenja pomoću alata za rješavanje u programu Microsoft Excel. Minimalne vrijednosti vodećeg vremena uz zadana ograničenja izračunate su za svaki mehanizam upravljanja, a one iznose:

$$LT_{Kanban-DA} = 54,5 \quad (min), \quad C_v = 1,5, t=4, Br=1$$

$$LT_{Conwip-DA} = 40,8 \quad (min), \quad C_v = 1,5, t=4, Br=1$$

$$LT_{Hibrid-DA} = 71 \quad (min), \quad C_v = 1,5, t=4, Br=1$$

$$LT_{DBR-DA} = 66 \quad (min), \quad C_v = 1,5, t=4, Br=1$$


Kako se vidi za postavljene uvjete minimalno vodeće vrijeme će se postići pomoću Conwip mehanizma upravljanja (slika 68) Dakle, u ovom slučaju optimalno je koristiti Conwip mehanizam upravljanja, te je optimalan broj upravljačkih kartica jednak jedan. Za isti broj kartica izračunate su razine produktivnosti:

$$P_{Kanban-DA} = 8,04 \quad \left(\frac{kom}{h}\right)$$

$$P_{Hibrid-DA} = 8,48 \quad (kom/h)$$

$$P_{Conwip-DA} = 8,15 \quad (kom/h)$$

$$P_{DBR-DA} = 8,3 \quad (kom/h)$$



Slika 68. Vodeće vrijeme $C_v=1,5$, $t=4$ min, $Br=1$ kom/RM

Nakon što je izračunom utvrđeno da se najkraće vodeće vrijeme kod sva četiri mehanizma upravljanja postiže za prosječno jednu upravljačku karticu po radnom mjestu, provedena je simulacija proizvodnog procesa kako je prethodno opisano na način da se mijenjao mehanizam upravljanja a broj upravljačkih kartica je jedna kartica po radnom mjestu. Najkraće vodeće vrijeme dobiveno simulacijom je postignuto za proces koji je upravljanja Conwip mehanizmom upravljanja, jednako kako se dobilo i izračunom pomoću matematičkih modela. U slučaju mjerne performanse produktivnost za isti broj kartica najveća produktivnost se postiže hibridnim mehanizmom upravljanja. Međutim, kako je postavljeni cilj minimalno vodeće vrijeme, optimalan odabir je Conwip mehanizam upravljanja. Drugačiji odnosi bi bili za različite razine broja upravljačkih kartica u procesu.

7. ZAKLJUČAK

Upravljanje proizvodnim procesima je složen zadatak. S jedne strane, stanje koje diktira tržište jako je zahtjevno i stalno se mijenja. Konkurencija je sve veća, a tu su i kupci čiji su zahtjevi bilo u pogledu kvalitete, bilo u pogledu cijene i raznolikosti modela i performansi određenog proizvoda, sve jasniji i veći. S druge strane jako je puno parametara koji mogu utjecati na performanse samog proizvodnog procesa i tu je zadatak voditelja proizvodnje ali i drugih stručnih osoba koji se bave upravljanjem proizvodnih procesa da kontinuirano unapređuju procese kako bi bilo moguće pratiti složene zahtjeve tržišta.

Do unatrag deset ili dvadeset godina, unapređenje proizvodnje je najčešće podrazumijevalo velike ili manje investicije u samu tehnologiju. Bolji uređaji, strojevi pomoću kojih se postiže brža obrada itd., jesu doprinosili boljim performansama proizvodnog procesa. No, kasnije se pokazalo da u samom postojećem procesu, bez ulaganja u nove, skuplje strojeve, postoji jako puno mogućnosti za unapređenje. Ovakvom načinu vođenja unapređenja proizvodnog procesa u mnogome je doprinijelo širenje pristupa proizvodnji koje je došlo iz Japana, prvenstveno iz proizvodnih pogona Toyote. Toyotin proizvodni sustav, kasnije prihvaćen u Europi i Sjedinjenim američkim državama, ali i diljem svijeta, kao princip Vitke proizvodnje, promijenio je pogled na mogućnosti unapređenja proizvodnih procesa.

Jedan od osnovnih ciljeva svake implementacije Vitke proizvodnje jeste smanjiti ukupan rad u procesu i skratiti vodeće vrijeme proizvodnog procesa. Mnogi su alati i principi Vitke proizvodnje kojima se to postiže. Postoji cijeli vremenski slijed implementacije tih alata i principa, kako bi se korak po korak došlo do postavljenog cilja. Jedan od principa je i princip povlačenja materijala u procesu. Primjena ovog principa je dosta složena, jer zahtjeva dugotrajnu posvećenost u usvajanju i primjeni različitih tehnika i alata Vitke proizvodnje da bi se došlo do predispozicije za uspješno uvođenje principa povlačenja u procesu. Kako bi se princip povlačenja implementirao kao način upravljanja proizvodnim procesom, koriste se različiti mehanizmi upravljanja proizvodnjom. Prvenstveno, tu se misli na Kanban. Kanban je osmišljen u Toyoti paralelno kako se razvijala ideja o povlačenju materijala u proizvodnom procesu, te je vremenom i postao sinonim za princip povlačenja. Kasnije su nastali, primjenjivani i istraživani i drugi mehanizmi upravljanja proizvodnjom kojima je isti zadatak a to je postizanje povlačenja materijala u proizvodnom procesu. Neki od njih su Conwip,

Hibrid Kanban/Conwip te DBR mehanizam upravljanja. Upravo ova četiri navedena mehanizma su istražena u ovom radu.

Cilj ovog rada bio je analizirati kako izbor mehanizma upravljanja proizvodnjom utječe na dvije mjerne performanse proizvodnog procesa a to su produktivnost i vodeće vrijeme, pri različitim karakteristikama proizvodnog procesa. Jedna od karakteristika proizvodnog procesa koja je istražena jeste postojanje usko grlo, te kako odluka o primjeni određenog mehanizma upravljanja utječe na navedene mjerne performanse ovisno o tome da li u procesu postoji ili ne postoji usko grlo. Nadalje, varirani su i slijedeći parametri, redom: koeficijent varijacije za vrijeme obrade, vrijeme trajanja obrade, te broj upravljačkih kartica (Kanban, Conwip i DBR kartice – ovisno koji je mehanizam upravljanja korišten u procesu).

Hipoteza rada je bila da je izborom odgovarajućeg mehanizma upravljanja proizvodnjom kojim se postiže povlačenje materijala kroz proces moguće optimalno unaprijediti performanse proizvodnog procesa. U tu svrhu provedeno je simulacijsko eksperimentiranje te su uspoređeni navedeni mehanizmi upravljanja.

Dobiveni rezultati pokazali su kako različit odabir mehanizma upravljanja proizvodnjom utječe na mjerne performanse proizvodnog procesa, te da pri različitim karakteristikama procesa (različite razine utjecajnih parametara) nije uvijek isti odabir mehanizma upravljanja dobar. U radu su povezana četiri mehanizma upravljanja proizvodnjom i ispitan je njihov utjecaj u različitim stanjima proizvodnog sustava. Značajno je što je i istražen utjecaj broja upravljačkih kartica na performanse za četiri različita mehanizma upravljanja proizvodnjom.

8. LITERATURA

- [1] Industry Week and Manufacturing Performance Institute: Manufacturing 2007–Executive Summary, 2007.
- [2] Womack, J. P. and Jones, D.T.: Lean Thinking: Banish Waste and Create Wealth in Your Corporation (2nd edition), New York: Simon & Schuster, 2003.
- [3] Murman, E., et. al.: Lean Enterprise Value: Insights from MIT's Lean Aerospace Initiative, Palgrave, New York, 2002.
- [4] Monden, Y.: Toyota Production System: An integrated approach to Just-In-Time (4th edition), Taylor & Francis Group, 2012.
- [5] Hopp, W. J., Spearman, M. C.: Factory Physics (3rd edition), Waveland Press Inc., 2008.
- [6] Chan F.T.S.: Effect of Kanban size on just in time manufacturing systems, Journal of materials Processing Technology 116, 146-160, 2001.
- [7] H. Jodlbauer H.: Customer driven production planning, International Journal of Production Economics. Vol. 111, Issue 2, 793-801, 2008.
- [8] Baykoc, O. F., Erol, S.: Simulation modeling and analysis of JIT production system, International Journal of Production Economics, Vol. 55, Issue 2, 203-212, 1998.
- [9] Enns, S. T.: Pull replenishment performance as a function of demand rates and setup times under optimal settings, Proceedings of the 2007 Winter Simulation Conference, Henderson S. G. et. al. editors, Piscataway, New Jersey: Institute of Electrical and Electronics Engineers, 1624-1632, 2007.
- [10] Yang, L., Zhang X. P.: Design and Application of Kanban Control System in a Multi-Stage, Mixed-Model Assembly Line, Systems Engineering — Theory & Practice Vol. 29, Issue 9, 2009.
- [11] Amos, H. C. N., Bernedixen J., Syberfeldt A.: A comparative study of production control mechanisms using simulation-based multi-objective optimization, International Journal of Production Research, Vol. 50, Issue 2, 359-377, 2012.
- [12] Lavoie P., Gharbi A., Kenne J. P.: A comparative study of pull control mechanisms for unreliable homogenous transfer lines, International Journal of Production Economics, Vol. 124, Issue 1, 241–251, 2010.
- [13] Pettersen J. A.: Pull Based Production Systems – Performance, Modeling and Analysis, doktorska disertacija, Lulea University of Technology, Švedska, 2010.

- [14] Pettersen, J. A., Segerstedt, A.: Restricted work-in-process: a study of differences between Kanban and CONWIP. *International Journal of Production Economics* Vol. 118, Issue 1, 199–207, 2009.
- [15] Sharma, S., Agrawal, N.: Selection of a pull production control policy under different demand situations for a manufacturing system by AHP-algorithm, *Computers & Operations Research* Vol. 36, Issue 5, 1622 – 1632, 2009.
- [16] Kabadurmus, O.: A comparative study of POLCA and Generic CONWIP production control systems in erratic demand conditions, *IIE Lean Division - Lean Student Paper Competition*, 2009.
- [17] Sandanayake, Y. G., Oduoza, C. F., Proverbs, D. G.: A systematic modeling and simulation approach for JIT performance optimization, *Robotics and Computer-Integrated Manufacturing* Vol. 24, Issue 6, 735-743, 2008.
- [18] Enns, S. T., Rogers, P.: Clarifying CONWIP versus PUSH system behavior using simulation, *Proceedings of the 2008 Winter Simulation Conference*, S. J. Mason, R. R. Hill, L. Mönch, O. Rose, T. Jefferson, J. W. Fowler editors, Piscataway, New Jersey: Institute of Electrical and Electronics Engineers, 1867 – 1872, 2008.
- [19] Cheraghi, H. S., Dadashzadeh, M., Soppin, M.: Comparative Analysis Of Production Control Systems Through Simulation, *Journal of Business & Economics Research*, Vol. 66, No. 5, 88 – 104, 2008.
- [20] Terrence, M. J.: A Simulation and Evaluation Study of the Economic Production Quantity Lot Size and Kanban for Single Line, Multi –Product Production System Under Various Setup Times, *doktroska disertacija*, Kent State University, SAD, 2008.
- [21] Bonvik A. M., Couch C. and Gershwin S. B.: A Comparison of Production-line Control Mechanisms, *International Journal of Production Research*, Volume 35, Issue 3, 1997.
- [22] Spearman, M.L., Woodruff, D.L., and Hopp. W.J. CONWIP: A Pull Alternative to Kanban, *International Journal of Production Research*, Vol. 28, No. 5, 879-894, 1990.
- [23] Suri, R.: *Quick Response Manufacturing. A Company Approach to Reducing Lead Times*, Productivity Press, 1998.
- [24] Riezebos, J.: Design of POLCA Material Control Systems, *International Journal of Production Research*, Vol. 48, Issue 5, 1455-1477, 2009.

- [25] Suri R., Krishnamurthy, A.: How to Plan and Implement POLCA: A Material Control System for High-Variety or Custom-Engineered Products, Technical Report, Center for Quick Response Manufacturing, 2003.
 - [26] Boonlertvanich, K.: Extended CONWIP-Kanban system: control and performance, doktorska disertacija, Georgia Institute of Technology, SAD, 2005.
 - [27] Lage Junior, M., Filho, M., G.: Variations of the Kanban system: Literature review and classification, International Journal of Production Economics, Vol. 125, Issue 1, 13–21, 2010.
 - [28] Prakash, J., Chin, J. F.: Variation of CONWIP Systems, World academy of Science, Engineering and Technology, Vol. 72, 2012.
 - [29] Chao, H., Shih, W. L.: Simulation studies in JIT production, International Journal of Production Research, 1992., Vol. 30, No. 11, 2573-2586, Published on-line 2007.
 - [30] Womack, J.P., Jones, D., Roos, D.: The Machine That Changed the World, Simon and Schuster, London, 2007.
 - [31] Ahrens Thorsten: Lean production: Successful implementation of organisational change in operations instead of short term cost reduction efforts, Lean Alliance, Germany, 2006.
 - [32] Askin, R., G., Goldberg, J., B.: Design and Analysis of Lean Production Systems, John Wiley and sons, 2002.
 - [33] Bicheno, L.: The New Lean Toolbox: Towards Fast Flexible Flow, Piccie Books, Buckingham, 2004.
 - [34] Darlingtona, J., Francisb, M., Founde, P., Thomasc, A.: Design and implementation of a Drum-Buffer-Rope pull-system, Production Planning & Control, Vol. 26, No. 6. 489-504, 2015
 - [35] Marek R.P., Elkins D. A., Smith D. R.: Understanding the fundamentals of Kanban and CONWIP pull systems using simulation, Proceeding of Winter Simulation Conference, 2001.
 - [36] Rotaru, A.: Performance Analyses of Conwip – Base stock controlled production system using simulation, Scientific bulletin, Automotive series, Faculty of Mechanics and Technology, University of Pitesti, year XVI, no.20 (1). 2010.
 - [37] Sergeant R. G. : Verification and validation of simulation models, Proceedings of the 2010 Winter simulation conference
 - [38] Matlab R2017b: <https://www.mathworks.com/products/simevents/whatsnew.html>
-

- [39] Gestettner, S., Kuhn, H.: Analysis of production control systems Kanban and Conwip, International Journal of Production and Research, 1996.
- [40] Design-Expert® Software Version 11: <https://www.statease.com/dx11.html>
- [41] Pavlić, I.: Statistička teorija i primjena, Tehnička knjiga Zagreb, 1970.
- [42] Cajner, Hrvoje; Tonković, Zlatko; Šakić, Nikola The THE SIGNIFICANCE OF DATA TRANSFORMATION IN ANALYSIS OF EXPERIMENTS. // 12th International Scientific Conference on Production Engineering : CIM 2009 / Eberhard, Abele ; Udiljak, Toma ; Ciglar, Damir (ur.). Zagreb: Croatian Association of Production Engineering, 2009.

9. PRILOG

Prilog A - 1. Rezultati simulacijskog eksperimentiranja po stanju pokusa kada se procesom upravlja Kanban mehanizmom upravljanja

Redoslijed izvođenja	Članovi modela					
	A Koeficijent varijacije	B Vrijeme obrade, min	C Usko grlo	D Broj kartica, kom/RM	Produktivnost, kom/h	Vodeće vrijeme, min
79	0,25	60	DA	5	0,7358	685
61	0,25	5	DA	5	8,91	35,5
12	0,86	60	NE	5	0,662511	2331
24	0,86	60	DA	2	0,4687	1041
56	0,86	60	DA	2	0,4798	858
2	0,86	5	NE	2	11,37	78,13
78	0,86	5	DA	5	8,4114	75,72
5	0,25	5	DA	2	8,89218	30,76
73	0,25	5	NE	5	11,9192	126,4
66	0,86	5	NE	2	11,391	68,67
47	0,25	60	DA	5	0,7261	630
51	0,25	60	NE	2	0,937762	870
75	0,25	60	NE	5	0,9615	1562
54	0,86	5	DA	2	8,40368	50,38
22	0,86	5	DA	2	8,40368	48,15
69	0,25	5	DA	2	8,90216	37,07
14	0,86	5	DA	5	8,42742	81,62
43	0,25	60	NE	5	0,9594	1641
67	0,25	60	NE	2	0,946778	800
32	0,86	60	DA	5	0,5497	1363
44	0,86	60	NE	5	0,66613	2187
1	0,25	5	NE	2	11,9043	69,4
6	0,86	5	DA	2	8,41359	49,72
68	0,86	60	NE	2	0,520305	758
23	0,25	60	DA	2	0,7266	621
21	0,25	5	DA	2	8,90216	35,33
25	0,25	5	NE	5	11,9262	128
35	0,25	60	NE	2	0,948248	893
46	0,86	5	DA	5	8,44544	64,63
42	0,86	5	NE	5	11,417	144,6
31	0,25	60	DA	5	0,7302	638
33	0,25	5	NE	2	11,9104	76,9
55	0,25	60	DA	2	0,7277	542
50	0,86	5	NE	2	11,41	78,12
17	0,25	5	NE	2	11,9161	72,05
19	0,25	60	NE	2	0,945308	769
80	0,86	60	DA	5	0,5251	1281
49	0,25	5	NE	2	11,9161	77,84
16	0,86	60	DA	5	0,4861	1125
41	0,25	5	NE	5	11,9352	135
71	0,25	60	DA	2	0,7261	658
28	0,86	60	NE	5	0,568699	1827

9. PRILOG

7	0,25	60	DA	2	0,7323	580
52	0,86	60	NE	2	0,525112	1209
13	0,25	5	DA	5	8,9276	35,74
63	0,25	60	DA	5	0,74	643
15	0,25	60	DA	5	0,7277	634
65	0,25	5	NE	2	11,9181	72,12
18	0,86	5	NE	2	11,41	87,37
74	0,86	5	NE	5	11,436	135,4
9	0,25	5	NE	5	11,9365	129
20	0,86	60	NE	2	0,537443	1712
77	0,25	5	DA	5	8,9297	37,07
4	0,86	60	NE	2	0,539638	1289
60	0,86	60	NE	5	0,605299	2293
53	0,25	5	DA	2	8,91214	36,38
59	0,25	60	NE	5	0,962	1524
3	0,25	60	NE	2	0,940212	952
64	0,86	60	DA	5	0,5425	1352
72	0,86	60	DA	2	0,5113	616
37	0,25	5	DA	2	8,92212	34,47
62	0,86	5	DA	5	8,45244	78,65
76	0,86	60	NE	5	0,641898	2364
48	0,86	60	DA	5	0,502	1100
45	0,25	5	DA	5	8,934	32,5
70	0,86	5	DA	2	8,43341	55,67
38	0,86	5	DA	2	8,45323	45,55
58	0,86	5	NE	5	11,465	133,8
11	0,25	60	NE	5	0,961	1659
10	0,86	5	NE	5	11,496	138,9
29	0,25	5	DA	5	8,937	34,37
40	0,86	60	DA	2	0,5225	719
39	0,25	60	DA	2	0,7246	559
34	0,86	5	NE	2	11,43	71,91
30	0,86	5	DA	5	8,45244	75,05
26	0,86	5	NE	5	11,533	121,7
8	0,86	60	DA	2	0,5471	977
57	0,25	5	NE	5	11,9447	127
27	0,25	60	NE	5	0,9538	1521
36	0,86	60	NE	2	0,551446	1001

Prilog A - 2. Rezultati simulacijskog eksperimentiranja po stanju pokusa kada se procesom upravlja Conwip mehanizmom upravljanja

Redoslijed izvođenja	Članovi modela					
	A Koefficient varijacije	B Vrijeme obrade, min	C Usko grlo	D Broj kartica, kom/RM	Produktivnost, kom/h	Vodeće vrijeme, min
56	0,86	60	DA	2	0,5149	904
51	0,25	60	NE	2	0,9728	534
47	0,25	60	DA	3	0,7358	1121
75	0,25	60	NE	3	0,971115	700
61	0,25	5	DA	3	8,935	99,36
64	0,86	60	DA	3	0,588179	1357
24	0,86	60	DA	2	0,5251	1056
3	0,25	60	NE	2	0,9656	499
18	0,86	5	NE	2	11,364	46,92
57	0,25	5	NE	3	11,93	33,76
21	0,25	5	DA	2	8,974	68,26
17	0,25	5	NE	2	11,92	36,23
35	0,25	60	NE	2	0,9579	519
76	0,86	60	NE	3	0,672078	701
26	0,86	5	NE	3	11,41	61,67
40	0,86	60	DA	2	0,5221	872
22	0,86	5	DA	2	8,48	67,66
31	0,25	60	DA	3	0,7261	1223
78	0,86	5	DA	3	8,462	114,5
27	0,25	60	NE	3	0,967075	645
79	0,25	60	DA	3	0,7302	1319
10	0,86	5	NE	3	11,42	60,82
50	0,86	5	NE	2	11,326	43,42
16	0,86	60	DA	3	0,561857	1397
11	0,25	60	NE	3	0,969696	577
25	0,25	5	NE	3	11,94	33,47
73	0,25	5	NE	3	11,94	35,31
19	0,25	60	NE	2	0,959	518
55	0,25	60	DA	2	0,7354	836
29	0,25	5	DA	3	8,946	99,65
53	0,25	5	DA	2	8,956	63,01
5	0,25	5	DA	2	8,943	64,39
6	0,86	5	DA	2	8,48	72,18
49	0,25	5	NE	2	11,93	33,77
1	0,25	5	NE	2	11,937	36,98
74	0,86	5	NE	3	11,45	59,79
36	0,86	60	NE	2	0,5327	559
48	0,86	60	DA	3	0,520127	1205
43	0,25	60	NE	3	0,968688	602
67	0,25	60	NE	2	0,957	499
12	0,86	60	NE	3	0,67575	814
30	0,86	5	DA	3	8,503	88,97
68	0,86	60	NE	2	0,5376	705
4	0,86	60	NE	2	0,5503	555
54	0,86	5	DA	2	8,49	59,37
44	0,86	60	NE	3	0,576912	644
33	0,25	5	NE	2	11,94	34,28

9. PRILOG

41	0,25	5	NE	3	11,94	33,25
60	0,86	60	NE	3	0,61404	608
52	0,86	60	NE	2	0,5525	699
63	0,25	60	DA	3	0,74	1228
34	0,86	5	NE	2	11,334	41,25
77	0,25	5	DA	3	8,927	103,7
39	0,25	60	DA	2	0,7262	851
14	0,86	5	DA	3	8,468	114,9
80	0,86	60	DA	3	0,580475	1166
42	0,86	5	NE	3	11,48	57,15
2	0,86	5	NE	2	11,364	44,66
62	0,86	5	DA	3	8,487	113,1
38	0,86	5	DA	2	8,51	62,12
65	0,25	5	NE	2	11,937	35,51
23	0,25	60	DA	2	0,7303	812
8	0,86	60	DA	2	0,5154	959
69	0,25	5	DA	2	8,945	35,02
66	0,86	5	NE	2	11,328	44,66
71	0,25	60	DA	2	0,7215	852
20	0,86	60	NE	2	0,5646	684
28	0,86	60	NE	3	0,651168	622
45	0,25	5	DA	3	8,925	104,2
59	0,25	60	NE	3	0,96143	611
7	0,25	60	DA	2	0,7277	848
32	0,86	60	DA	3	0,53714	1333
13	0,25	5	DA	3	8,932	106,7
46	0,86	5	DA	3	8,547	100,1
70	0,86	5	DA	2	8,59	64,14
9	0,25	5	NE	3	11,95	35,03
72	0,86	60	DA	2	0,521	949
15	0,25	60	DA	3	0,7277	1382
37	0,25	5	DA	2	8,959	32,94
58	0,86	5	NE	3	11,47	62,51

Prilog A - 3. Rezultati simulacijskog eksperimentiranja po stanju pokusa kada se procesom upravlja hibrid Kanban/Conwip mehanizmom upravljanja

Redosljed izvođenja	Članovi modela					
	A Koeficijent varijacije	B Vrijeme obrade, min	C Usko grlo	D Broj kartica, kom/RM	Produktivnost, kom/h	Vodeće vrijeme, min
64	0,86	60	DA	3	0,5568	1233
26	0,86	5	NE	3	11,4524	59,44
74	0,86	5	NE	3	11,4715	57,68
2	0,86	5	NE	2	11,3676	43,466
22	0,86	5	DA	2	8,593	74,992
32	0,86	60	DA	3	0,5319	1263
48	0,86	60	DA	3	0,4924	1238
71	0,25	60	DA	2	0,7276	848
17	0,25	5	NE	2	11,9389	34,02
5	0,25	5	DA	2	8,9441	62,9381
46	0,86	5	DA	3	8,552	84,3
30	0,86	5	DA	3	8,568	89,94
66	0,86	5	NE	2	11,3415	41,416
53	0,25	5	DA	2	8,9558	64,9937
78	0,86	5	DA	3	8,587	99,19
25	0,25	5	NE	3	0,7328	863
14	0,86	5	DA	3	8,594	91,42
44	0,86	60	NE	3	0,647	716
70	0,86	5	DA	2	8,626	79,886
11	0,25	60	NE	3	11,977	35,93
79	0,25	60	DA	3	8,961	90,42
21	0,25	5	DA	2	8,9554	65,2699
50	0,86	5	NE	2	11,4522	44,038
9	0,25	5	NE	3	11,9514	34,37
37	0,25	5	DA	2	8,9657	68,3127
31	0,25	60	DA	3	0,728059	958
18	0,86	5	NE	2	11,449	43,197
3	0,25	60	NE	2	0,9625	532
55	0,25	60	DA	2	0,7269	1082
57	0,25	5	NE	3	11,9584	35,28
42	0,86	5	NE	3	11,5005	57,56
29	0,25	5	DA	3	0,9661	623
20	0,86	60	NE	2	0,5161	569
65	0,25	5	NE	2	11,9615	35,307
33	0,25	5	NE	2	11,947	36,195
16	0,86	60	DA	3	0,5495	945
15	0,25	60	DA	3	0,732221	1135
10	0,86	5	NE	3	11,5316	57,7
68	0,86	60	NE	2	0,5209	687
8	0,86	60	DA	2	0,522	872
59	0,25	60	NE	3	0,974	716
12	0,86	60	NE	3	0,6505	913
75	0,25	60	NE	3	0,9718	631
63	0,25	60	DA	3	0,742066	1030
28	0,86	60	NE	3	0,6554	639
61	0,25	5	DA	3	8,934	95,15
39	0,25	60	DA	2	0,722	810

9. PRILOG

60	0,86	60	NE	3	0,6111	868
62	0,86	5	DA	3	8,594	85,92
6	0,86	5	DA	2	8,5958	74,446
1	0,25	5	NE	2	11,923	35,28
23	0,25	60	DA	2	0,7256	833
36	0,86	60	NE	2	0,5331	517
7	0,25	60	DA	2	0,722	725
43	0,25	60	NE	3	0,9745	606
38	0,86	5	DA	2	8,6092	71,61
24	0,86	60	DA	2	0,5123	1080
52	0,86	60	NE	2	0,5353	699
54	0,86	5	DA	2	8,586	79,83
49	0,25	5	NE	2	11,9317	35,121
34	0,86	5	NE	2	11,4723	42,162
41	0,25	5	NE	3	11,9674	34,26
58	0,86	5	NE	3	11,5688	59,05
56	0,86	60	DA	2	0,5184	916
4	0,86	60	NE	2	0,547	697
19	0,25	60	NE	2	0,9656	513
69	0,25	5	DA	2	8,9757	67,0289
72	0,86	60	DA	2	0,5077	847
80	0,86	60	DA	3	0,5085	1506
77	0,25	5	DA	3	8,952	94,46
47	0,25	60	DA	3	0,729684	1221
35	0,25	60	NE	2	0,9683	507
51	0,25	60	NE	2	0,96154	547
40	0,86	60	DA	2	0,5205	819
73	0,25	5	NE	3	11,9687	35,44
13	0,25	5	DA	3	8,954	89,9
27	0,25	60	NE	3	0,9734	620
45	0,25	5	DA	3	8,958	93,55
76	0,86	60	NE	3	0,6269	923
67	0,25	60	NE	2	0,95691	522

Prilog A - 4. Rezultati simulacijskog eksperimentiranja po stanju pokusa kada se procesom upravlja DBR mehanizmom upravljanja

Redoslijed izvođenja	Članovi modela					
	A Koeficijent varijacije	B Vrijeme obrade, min	C Usko grlo	D Broj kartica, kom/RM	Produktivnost, kom/h	Vodeće vrijeme, min
79	0,25	60	DA	3,5	0,747939	1208
18	0,86	5	NE	2,25	11,387	51,408
20	0,86	60	NE	2,25	0,6164	596
59	0,25	60	NE	3,5	0,955385	580
32	0,86	60	DA	3,5	0,571312	1113
47	0,25	60	DA	3,5	0,75639	1098
26	0,86	5	NE	3,5	11,421	50,683
73	0,25	5	NE	3,5	11,9609	38,44
23	0,25	60	DA	2,25	0,736492	851
38	0,86	5	DA	2,25	8,595	67,35
55	0,25	60	DA	2,25	0,728715	808
40	0,86	60	DA	2,25	0,5395	788
28	0,86	60	NE	3,5	0,6006	795
41	0,25	5	NE	3,5	11,9549	33,94
9	0,25	5	NE	3,5	11,9669	34,438
76	0,86	60	NE	3,5	0,6314	681
27	0,25	60	NE	3,5	0,964103	588
68	0,86	60	NE	2,25	0,5897	511
31	0,25	60	DA	3,5	0,73579	1195
58	0,86	5	NE	3,5	11,412	48,038
30	0,86	5	DA	3,5	8,60618	101,822
36	0,86	60	NE	2,25	0,6144	612
4	0,86	60	NE	2,25	0,6036	768
10	0,86	5	NE	3,5	11,417	50,194
12	0,86	60	NE	3,5	0,578527	836
3	0,25	60	NE	2,25	0,951	580
70	0,86	5	DA	2,25	8,608	73,65
64	0,86	60	DA	3,5	0,562615	1556
39	0,25	60	DA	2,25	0,731846	839
44	0,86	60	NE	3,5	0,66374	629
24	0,86	60	DA	2,25	0,5159	722
53	0,25	5	DA	2,25	8,987	63,184
19	0,25	60	NE	2,25	0,9595	583
14	0,86	5	DA	3,5	8,60618	99,558
78	0,86	5	DA	3,5	8,63924	106,943
72	0,86	60	DA	2,25	0,5323	836
62	0,86	5	DA	3,5	8,6172	101,293
52	0,86	60	NE	2,25	0,5856	697
49	0,25	5	NE	2,25	11,94	34,019
2	0,86	5	NE	2,25	11,423	49,57
42	0,86	5	NE	3,5	11,388	52,534
57	0,25	5	NE	3,5	11,9609	34,687
54	0,86	5	DA	2,25	8,58	82,082
45	0,25	5	DA	3,5	8,97959	95,551
71	0,25	60	DA	2,25	0,739623	781
37	0,25	5	DA	2,25	8,9818	63,202
33	0,25	5	NE	2,25	11,96	35,307

9. PRILOG

66	0,86	5	NE	2,25	11,391	50,676
67	0,25	60	NE	2,25	0,9615	568
69	0,25	5	DA	2,25	8,98	63,5
48	0,86	60	DA	3,5	0,5512	1406
22	0,86	5	DA	2,25	8,591	74,869
74	0,86	5	NE	3,5	11,431	52,358
13	0,25	5	DA	3,5	8,99165	99,283
34	0,86	5	NE	2,25	11,377	51,048
75	0,25	60	NE	3,5	0,963077	536
21	0,25	5	DA	2,25	8,9708	64,463
43	0,25	60	NE	3,5	0,962564	562
61	0,25	5	DA	3,5	8,99465	96,505
46	0,86	5	DA	3,5	8,63423	106,17
50	0,86	5	NE	2,25	11,417	47,221
60	0,86	60	NE	3,5	0,610866	677
11	0,25	60	NE	3,5	0,963077	564
29	0,25	5	DA	3,5	8,98763	99,99
7	0,25	60	DA	2,25	0,738613	806
17	0,25	5	NE	2,25	11,947	36,195
77	0,25	5	DA	3,5	8,98161	96,82
63	0,25	60	DA	3,5	0,742657	1208
8	0,86	60	DA	2,25	0,5207	850
65	0,25	5	NE	2,25	11,923	35,28
5	0,25	5	DA	2,25	8,976	64,54
16	0,86	60	DA	3,5	0,578379	1512
56	0,86	60	DA	2,25	0,5221	880
80	0,86	60	DA	3,5	0,559897	1712
15	0,25	60	DA	3,5	0,745826	1210
6	0,86	5	DA	2,25	8,6	73,58
51	0,25	60	NE	2,25	0,9538	579
1	0,25	5	NE	2,25	11,931	35,125
25	0,25	5	NE	3,5	11,9589	34,81
35	0,25	60	NE	2,25	0,958	585

ŽIVOTOPIS

Nataša Tošanović, dipl. ing stroj. rođena je 23. 4. 1979. u Zenici, BiH. Diplomirala je u srpnju 2007. godine na Fakultetu strojarstva i brodogradnje, smjer Proizvodno strojarstvo, usmjerenje Industrijsko inženjerstvo.

Od veljače 2008. Do rujna 2009. godine radila je kao stručni suradnik na projektu *Postizanje poslovne izvrsnosti implementacijom lean sustava u proizvodnim i uslužnim poduzećima Republike Hrvatske*, koji je bio financiran od strane *Zaklade Adris*. Na projektu se bavila istraživanjem mogućnosti primjene *lean* sustava u hrvatskim poduzećima. U sklopu navedenog projekta boravila je tijekom srpnja 2008. godine na Massachusetts Institute of Technology, gdje je prošla edukaciju iz područja *lean* sustava.

Od rujna 2009. Zaposlena je kao asistentica na Zavodu za industrijsko inženjerstvo.

U razdoblju od 2008. do 2013. godine radila je kao suradnik na projektu „Unapređenje poslovanja malih i srednjih poduzeća primjenom *lean* sustava“ koji je bio financiran od strane Ministarstva gospodarstva rada i poduzetništva. Sudjelovala je kao predavač na više seminara iz područja *lean* sustava u organizaciji Centra za transfer tehnologije, Hrvatskog društva održatelja, Centra za razvoj proizvoda, Fakulteta strojarstva i brodogradnje iz Zagreba i Fakulteta elektrotehnike strojarstva i brodogradnje iz Splita. Godine 2009. sudjelovala je u izobrazbi za postizanje stupnja Zeleni pojas iz područja Sigma+ (Šest sigma) organiziranoj u poduzeću Končar Power Transformers Ltd. U istom poduzeću, 2011. godine sudjelovala je na projektu obrazovanja zaposlenika iz područja *lean* sustava, te organizirala i vodila radionice sa specifičnim temama o unapređenju proizvodnog procesa. Također, tijekom 2012. godine sudjelovala je na tri projekta izobrazbe zaposlenika iz područja Vitke proizvodnje i implementacije principa Vitke proizvodnje. Projekti su bili organizirani u slijedećim poduzećima: Novi Feromont d.o.o., Potomac d.o.o. i Županijske ceste Zagrebačke županije d.o.o.

Govori i piše engleski jezik

BIOGRAPHY

Nataša Tošanović was born on April 23th 1979 in Zenica, BiH. She graduated at the Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb in 2007. after she completed the program of Production and Industrial Engineering of University undergraduate studies.

During the period from February 2008 and September 2009 she has worked as associate on a project „Achieving Business excellence by applying Lean systems in production and service companies in Republic of Croatia“ which was funded by The Adris Foundation. She was researching possibilities of applying Lean systems in Croatian companies. As part of that project she attended courses in Lean systems at the Massachusetts Institute of Technology.

Since September 2009 she has been employed as an assistant at the Department of Industrial Engineering, Faculty of Mechanical Engineering, University of Zagreb. In the period from 2008 to 2013 he worked as an associate on the project "Improving Small and Medium sized Enterpris Businesses using Lean Systems", which was funded by the Ministry of Entrepreneurship and Crafts. She participated as a lecturer on several Lean system seminars, organized by the Center for Technology Transfer, the Croatian Maintenance Society, the Product Development Center, the Faculty of Mechanical Engineering and Naval Architecture from Zagreb and the Faculty of Electrical Engineering Mechanical Engineering and Naval Architecture from Split In 2009. she was lecturer in Green Belt Six Sigma training at the company Koncar Power Transformers Ltd. During the 2011, she participated in employees training in Lean systems and also organized and conducted Kaizen workshops in the same company. During the 2012 she participated in employees training in Lean systems. Trainings were organized in companies: Novi Feromont, Potomac and Županijske ceste. She speaks English.